

MINISTÉRIO DA EDUCAÇÃO
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE
GOIÁS
DEPARTAMENTO DE ÁREAS ACADÊMICAS III
CURSO DE ENGENHARIA DE TRANSPORTES

**A INFLUÊNCIA DA PRESENÇA DE CHUVA NO
COMPORTAMENTO DE CONDUTORES NO MEIO
URBANO: UM ESTUDO NATURALÍSTICO DE
DIREÇÃO.**

Isabela Pereira Macedo Dutra

GOIÂNIA
2025

**TERMO DE AUTORIZAÇÃO PARA DISPONIBILIZAÇÃO
NO REPOSITÓRIO DIGITAL DO IFG - ReDi IFG**

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia de Goiás, a disponibilizar gratuitamente o documento no Repositório Digital (ReDi IFG), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IFG.

Identificação da Produção Técnico-Científica

- | | |
|--|---|
| ☐ Tese | ☐ Artigo Científico |
| ☐ Dissertação | ☐ Capítulo de Livro |
| ☐ Monografia – Especialização | ☐ Livro |
| ☒ TCC - Graduação | ☐ Trabalho Apresentado em Evento |
| ☐ Produto Técnico e Educacional - Tipo: _____ | |

Nome Completo do Autor: Isabela Pereira Macedo Dutra

Matrícula: 20201011180145

Título do Trabalho: A influência da presença de chuva no comportamento de condutores no meio urbano: um estudo naturalístico de direção.

Autorização - Marque uma das opções

- ☒ Autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso aberto);
- ☐ Autorizo disponibilizar meu trabalho no Repositório Digital do IFG somente após a data ____/____/____ (Embargo);
- ☐ Não autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso restrito).

Ao indicar a opção **2 ou 3**, marque a justificativa:

- ☐ O documento está sujeito a registro de patente.
☐ O documento pode vir a ser publicado como livro, capítulo de livro ou artigo.
☐ Outra justificativa: _____

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

- o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia de Goiás os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

Isabela Pereira Macedo Dutra

**A INFLUÊNCIA DA PRESENÇA DE CHUVA NO
COMPORTAMENTO DE CONDUTORES NO MEIO
URBANO: UM ESTUDO NATURALÍSTICO DE
DIREÇÃO.**

Trabalho de Conclusão de Curso apresentado à
Coordenação do Curso de Engenharia de Transportes,
do Instituto Federal de Educação, Ciência e
Tecnologia de Goiás – Campus Goiânia, como
requisito parcial para obtenção do título de Bacharel
em Engenharia de Transportes.

Orientador(a): Profa. Dra. Mariana de Paiva

GOIÂNIA
2025

D978i Dutra, Isabela Pereira Macedo.

A influência da presença de chuva no comportamento de condutores no meio urbano: um estudo naturalístico de direção. Goiânia: Instituto Federal de Educação, Ciência e Tecnologia de Goiás, 2025. 199f.

Orientação: Prof. Dra. Mariana de Paiva.

TCC (Trabalho de Conclusão de Curso) – Curso de Engenharia de Transportes, Departamento de Áreas Acadêmicas III, Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

1. Segurança viária. 2. Comportamento de condutores. 3. Sinistros de trânsito. I. Paiva, Mariana de (orientação). II. Instituto Federal de Educação, Ciência e Tecnologia de Goiás. III. Título.

CDD 363.125 1

ATA DE DEFESA DE TRABALHO DE CONCLUSÃO DE CURSO

Na presente data realizou-se a sessão pública de defesa do Trabalho de Conclusão de Curso intitulada **A INFLUÊNCIA DA PRESENÇA DE CHUVA NO COMPORTAMENTO DE CONDUTORES NO MEIO URBANO: UM ESTUDO NATURALÍSTICO DE DIREÇÃO**, sob orientação de Mariana de Paiva, apresentada pela aluna **Isabela Pereira Macedo Dutra (20201011180145)** do Curso **Bacharelado em Engenharia de Transportes (Câmpus Goiânia)**. Os trabalhos foram iniciados às **14:00** do dia **19/03/2025** pela Professora presidente da banca examinadora, constituída pelos seguintes membros:

- **Mariana de Paiva** (Presidente)
- **Luciana Araujo Azevedo de Oliveira** (Examinadora Interna)
- **Denis Biolkino de Sousa Pereira** (Examinador Interno)

A banca examinadora, tendo terminado a apresentação do conteúdo do Trabalho de Conclusão de Curso, passou à arguição da candidata. Em seguida, os examinadores reuniram-se para avaliação e deram o parecer final sobre o trabalho apresentado pelo aluno, tendo sido atribuído o seguinte resultado:

☒ Aprovado

☐ Reprovado

Nota : 10,0

Observação / Apreciações:

Proclamados os resultados pelo presidente da banca examinadora, foram encerrados os trabalhos e, para constar, eu **Mariana de Paiva** lavrei a presente ata que assino juntamente com os demais membros da banca examinadora.

Documento assinado eletronicamente por:

- **Luciana Araujo Azevedo de Oliveira** (492.317.823-04), em **09/09/2025 14:09:22** com chave **bb33b1688d9f11f08d8e005056a537a4**.
- **Mariana de Paiva** (055.489.606-01), em **09/09/2025 13:57:08** com chave **0575c1e68d9e11f08307005056a537a4**.
- **Denis Biolkino de Sousa Pereira** (307.778.871-34), em **09/09/2025 15:35:51** com chave **cfaab4aa8dab11f0a6b2005056a537a4**.

Este documento foi emitido pelo SUAP. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse https://suap.ifg.edu.br/comum/autenticar_documento/ e informe os dados a seguir.

Tipo de Documento: Ata de Projeto Final

Data da Emissão: 09/09/2025

Código de Autenticação: 9b78ef



AGRADECIMENTOS

A Deus, pelo amparo e pela força concedidos ao longo desta caminhada acadêmica.

À memória de meu pai, cuja perda em um acidente de trânsito motivou minha busca por contribuir para a segurança viária.

Ao meu parceiro de espécie, Maxmiller, pelo amor, incentivo e paciência em todos os momentos desta trajetória.

À minha mãe e aos meus irmãos, meus amores para toda a vida, exemplos de dedicação, coragem e afeto, a quem esta vitória também é oferecida com gratidão.

À Professora Dra. Mariana, orientadora deste trabalho, pela confiança, orientação e apoio.

Ao Professor Me. José Gustavo, pelas contribuições valiosas ao longo do desenvolvimento deste trabalho, que enriqueceram esta pesquisa.

À Universidade Federal do Paraná (UFPR), pela disponibilização dos dados à realização desta pesquisa, e ao Dr. Jorge Tiago Bastos, pelo suporte e pela valiosa contribuição acadêmica.

Aos amigos, pelo apoio, incentivo e pela leveza que tornaram esta caminhada mais suportável.

*Entre cálculos, mapas e estatísticas carrego a
ausência que me ensinou porque a segurança
viária não é apenas técnica – é vida.*

Isabela

RESUMO

Este trabalho analisa os efeitos das condições ambientais adversas sobre o comportamento de condutores em meio urbano, considerando precipitação, luminosidade e variação de fluxo viário. Foram testadas seis hipóteses, sendo três em nível global, avaliando diferenças de comportamento entre os cenários de chuva e sua ausência, períodos diurno e noturno e horários de pico e entre picos, e três em nível individual, verificando a resposta de cada condutor em condições de precipitação distintas. A base empírica foi composta por dados naturalísticos de direção do projeto NDS-BR, coletados na Região Metropolitana de Curitiba entre 2019 e 2021, com registros contínuos de condução em condições reais de tráfego. A análise contemplou três dimensões principais do comportamento longitudinal: (i) tempo de permanência em faixas de velocidade relativa (V1, V2 e V3), (ii) aceleração normal e brusca (A1 e A2) e (iii) frenagem normal e abrupta (F1 e F2). Foram empregadas estatísticas descritivas e testes não paramétricos (*Mann-Whitney*, *Kruskal-Wallis* e *Dunn* com correção de *Holm*), complementados por estimador de *Hodges-Lehmann* e reamostragem bootstrap BCa com 2.000 replicações, de modo a captar diferenças mesmo em distribuições não normais. Os resultados mostraram que a precipitação esteve associada à redução da velocidade relativa e à menor ocorrência de acelerações moderadas, além de maior heterogeneidade em acelerações bruscas e maior dispersão nas frenagens abruptas. No período noturno, verificou-se uma uniformização das respostas moderadas (A1 e F1) e, em contrapartida, maior variabilidade nos comportamentos bruscos (A2 e F2), sugerindo influência da baixa visibilidade na intensificação de reações mais extremas. Nos horários de pico, o comportamento foi mais homogêneo e cauteloso, em contraste com a heterogeneidade observada no entre picos. A análise individual evidenciou que alguns condutores mantiveram condutas agressivas mesmo em cenários adversos, enquanto outros ajustaram significativamente sua forma de condução, demonstrando o papel dos fatores pessoais na modulação da resposta às condições externas. Conclui-se que as seis hipóteses foram confirmadas em diferentes magnitudes, indicando que chuva, luminosidade e fluxo de tráfego impactam significativamente velocidade, aceleração e frenagem. O estudo contribui com evidências no contexto brasileiro, reforçando a importância de considerar simultaneamente fatores ambientais e individuais no planejamento de políticas de segurança viária e na formulação de estratégias preventivas para reduzir riscos em ambientes urbanos.

Palavras-chave: Estudo naturalístico de direção; precipitação; luminosidade; fluxo viário; comportamento de condutores; segurança viária.

Abstract

This study analyzes the effects of adverse environmental conditions on driver behavior in urban settings, considering precipitation, lighting, and traffic flow variation. Six hypotheses were tested: three at the global level, assessing behavioral differences between rainy and dry conditions, daytime and nighttime periods, and peak and off-peak hours; and three at the individual level, examining how each driver responded to different precipitation scenarios. The empirical basis consisted of naturalistic driving data from the NDS-BR project, collected in the Metropolitan Region of Curitiba between 2019 and 2021, with continuous driving records under real traffic conditions. The analysis focused on three main dimensions of longitudinal behavior: (i) time spent in relative speed ranges (V1, V2, V3), (ii) normal and abrupt acceleration (A1 and A2), and (iii) normal and abrupt braking (F1 and F2). Descriptive statistics and non-parametric tests (Mann-Whitney, Kruskal-Wallis, and Dunn with Holm correction) were employed, complemented by the Hodges-Lehmann estimator and BCa bootstrap resampling with 2,000 replications to capture differences even in non-normal distributions. The results showed that precipitation was associated with reduced relative speed and less frequent moderate accelerations, as well as greater heterogeneity in abrupt accelerations and increased dispersion in abrupt braking. At night, moderate responses (A1 and F1) became more uniform, whereas abrupt behaviors (A2 and F2) exhibited higher variability, suggesting the influence of reduced visibility on more extreme reactions. During peak hours, behavior was more homogeneous and cautious, contrasting with the heterogeneity observed in off-peak periods. The individual-level analysis revealed that while some drivers maintained aggressive conduct even under adverse scenarios, others significantly adjusted their driving style, underscoring the role of personal factors in shaping responses to external conditions. It is concluded that all six hypotheses were confirmed to varying degrees, indicating that rainfall, lighting, and traffic flow significantly affect speed, acceleration, and braking. The study provides novel evidence in the Brazilian context and reinforces the importance of simultaneously considering environmental and individual factors in road safety planning and in the development of preventive strategies to reduce risks in urban environments.

Keywords: Naturalistic Driving Study; Adverse Weather; Rainfall; Nighttime Driving; Traffic Flow; Driver Behavior; Speed; Acceleration; Braking; Road Safety.

LISTA DE FIGURAS

Figura 1.1 Estrutura do Trabalho.....	19
Figura 2.1 Mortes no Trânsito por País.....	21
Figura 2.2 Diagrama esquemático das relações de trânsito.....	22
Figura 4.1 mostra o procedimento de reamostragem pelo referido método.	55
Figura 5.1 Fluxograma 1 – Etapas metodológicas comuns às hipóteses	61
Figura 5.2 Fluxograma 2 – Etapas metodológicas por conjunto de Hipóteses.....	62
Figura 5.3 Esquema dos equipamentos utilizados	64
Figura 5.4 Fluxograma para comparação mais de dois grupos.....	75
Figura 5.5: Fluxograma para comparação entre dois grupos	78
Figura 6.1. Estações Pluviométrica presentes em Curitiba.....	85
Figura 6.2 % de tempo de permanência em faixas de V, A e F (sem chuva e com chuva).....	95
Figura 6.3 Boxplot: % de tempo de permanência em faixas de V, A e F (Diurno e Noturno sob. chuva). 107	
Figura 6.4 Boxplot: % de tempo de permanência em faixas de V, A e F (Pico e entre picos, sob chuva).. 119	
Figura 6.5 Boxplot: Velocidade Relativa de cada condutores (chuva e sem chuva)	130
Figura 6.6 <i>Boxplot</i> : Aceleração de cada condutores (chuva e sem chuva).....	138
Figura 6.7. <i>Boxplot</i> : Frenagem de cada condutores (chuva e sem chuva)	145
Figura 6.8 Boxplot: Velocidade de cada condutor (período diurno e noturno, sob chuva)	152
Figura 6.9 Boxplot: Aceleração de cada condutor (dia e noite, sob chuva).....	156
Figura 6.10 Boxplot: Frenagem de cada condutores (dia e noite, sob chuva)	160
Figura 6.11 Boxplot: Velocidade de cada condutor (pico e entre pico, sob chuva).....	164
Figura 6.12 Boxplot: Aceleração de cada condutor (picos e entre picos, sob chuva).....	169

LISTA DE TABELAS

Tabela 6.1. Período de monitoramento, quantidade e tempo de viagens dos condutores	83
Tabela 6.2. Latitude e Longitude das Estações Pluviométricas de Curitiba	85
Tabela 6.3. Transformação de Latitude e Longitude em UTM (localização do condutor)	86
Tabela 6.4. Identificação da estação mais próxima do condutor.....	87
Tabela 6.5. Combinação dos dados meteorológicos e de condução	88
Tabela 6.6. Classificação das condições meteorológicas.....	89
Tabela 6.7. Subdivisão das viagens conforme mudança na condição climática.....	90
Tabela 6.8 Classificação das subviagens com e sem chuva, diurno e noturno e Pico e entre picos	91
Tabela 6.9 Tempo de permanência em cada faixa de Velocidade, Aceleração e Frenagem (%).....	93
Tabela 6.10 Estatísticas descritivas: % V, A, F e IQR (sem chuva vs chuva)	95
Tabela 6.11. Teste de Normalidade: D'Agostino-Pearson ou de Shapiro-Wilk (sem chuva vs com chuva)	98
Tabela 6.12. IC e A: amostras originais e com <i>bootstrap</i> para V, A e F (sem chuva vs com chuva).....	98
Tabela 6.13 Teste não paramétrico de Kruskal-Wallis: velocidades (sem chuva vs com chuva)	99
Tabela 6.14 Teste Dunn – Amostra Original e com <i>bootstrap</i> (sem chuva vs com chuva).....	100
Tabela 6.15 Teste de U Mann-Whitney aplicado às condições de chuva e sua ausência.....	103
Tabela 6.16 Estatísticas descritivas: % V, A, F e IQR (dia e noite sob. chuva)	106
Tabela 6.17 Teste de Normalidade: D'Agostino-Pearson ou de Shapiro-Wilk (diurno e noturno, sob chuva).....	110
Tabela 6.18. IC e A: amostras originais e com <i>bootstrap</i> para V, A e F (Diurno e Noturno, sob chuva) ...	111
Tabela 6.19 Teste não paramétrico de Kruskal-Wallis: velocidades (período diurno e noturno, sob chuva)	111
Tabela 6.20 Teste Dunn – Amostra Original e <i>bootstrap</i> (BCa) (Diurno vs noturno, ambos sob chuva)...	112
Tabela 6.21 Teste de U Mann-Whitney aplicado períodos Diurno e Noturno sob. chuva	115
Tabela 6.22 Estatísticas descritivas: % V, A, F e IQR (Pico e entre picos, sob chuva)	118
Tabela 6.23 Teste de Normalidade: D'Agostino-Pearson ou de Shapiro-Wilk (Pico e Entre pico, sob chuva)	121
Tabela 6.24 IC e A: amostras originais com <i>bootstrap</i> para V, A e F (Pico e entre pico, sob chuva)	122
Tabela 6.25 Teste não paramétrico de Kruskal-Wallis: velocidades (pico e entre picos, sob chuva).....	122
Tabela 6.26. Teste Dunn – Amostra Original e com <i>bootstrap</i> (período pico e entre picos, sob chuva).....	123
Tabela 6.27 Teste de U Mann-Whitney aplicado períodos Pico e Entre pico, sob chuva.....	125
Tabela 6.28. Estatística descritiva: velocidade individualizada (chuva e sem chuva)	129
Tabela 6.29 Testes de Normalidade: Shapiro-Wilk ou D'Agostino-Pearson: Velocidade (com e sem chuva)	133
Tabela 6.30. Teste não paramétrico (U Mann-Whitney) aplicado às condições de chuva e sua ausência .	134
Tabela 6.31. Estatística descritiva: aceleração (com chuva e sem chuva)	136
Tabela 6.32. Testes de normalidade para aceleração (com e sem chuva).....	141
Tabela 6.33. Teste não paramétrico (U Mann-Whitney) para aceleração (com chuva e sem chuva)	142

Tabela 6.34. Estatística descritiva: frenagem (chuva e sem chuva)	144
Tabela 6.35. Teste de normalidade para frenagem (com e sem chuva)	148
Tabela 6.36. Teste não paramétrico (U Mann-Whitney) para frenagem (com e sem chuva)	149
Tabela 6.37. Estatística descritiva: velocidade individualizada (período diurno e noturno, sob chuva) ...	151
Tabela 6.38. Teste de normalidade para velocidades relativas (dia e noite, sob chuva).....	153
Tabela 6.39. Teste não paramétrico para velocidades (U Mann-Whitney): dia e noite, sob chuva.....	154
Tabela 6.40 Estatística descritiva para aceleração (dia e noite, sob chuva)	155
Tabela 6.41 Teste de normalidade para aceleração (dia e noite, sob chuva).....	157
Tabela 6.42 Teste não paramétrico (U de Mann-Whitney) para aceleração: diurno e noturno, sob chuva	158
Tabela 6.43 Estatística descritiva: frenagem (dia e noite, sob chuva).....	159
Tabela 6.44 Teste de normalidade: Shapiro-Wilk ou D'Agostino-Pearson (dia e noite, sob chuva).....	161
Tabela 6.45 Teste não paramétrico (U Mann-Whitney) para frenagem: dia e noite, sob chuva	162
Tabela 6.46 Estatísticas descritivas de velocidade (picos e entre picos, sob chuva	163
Tabela 6.47 Teste de normalidade para velocidades relativas (picos e entre picos, sob chuva)	166
Tabela 6.48 Teste não paramétrico para velocidades (U Mann-Whitney): picos e entre picos, sob chuva	166
Tabela 6.49 Estatísticas descritivas de aceleração (picos e entre picos, sob chuva).....	168
Tabela 6.50 Teste de normalidade para aceleração (picos e entre picos, sob chuva).....	170
Tabela 6.51. Teste não paramétrico (U de Mann-Whitney) para aceleração: picos e entre picos, sob chuva	171
Tabela 6.52 Estatísticas descritivas de frenagem (picos e entre picos, sob chuva).....	173
Tabela 6.53 Teste de normalidade: Shapiro-Wilk ou D'Agostino-Pearson (picos e entre picos, sob chuva)	175
Tabela 6.54 Teste não paramétrico (U Mann-Whitney) :pico e entre picos, sob chuva	176

SUMÁRIO

1. INTRODUÇÃO	14
1.1 Hipóteses	15
1.2 Objetivo	16
1.2.1 Objetivo Geral	16
1.2.2 Objetivos Específicos	16
1.3 Justificativa	17
1.4 Metodologia	18
1.5 Estrutura do trabalho	18
2. SINISTROS DE TRÂNSITO	20
2.1 Considerações iniciais	20
2.2 Contextualização de sinistros de trânsito	20
2.3 Sinistros de trânsito no Brasil e no Mundo	20
2.4 Fatores associados aos sinistros de trânsito	21
2.4.1 Fatores humanos	23
2.4.2 Fatores da via/veículo	25
2.4.3 Fatores Ambientais	26
2.4.3.1 Estudos sob Comportamento dos condutores em condições climáticas adversas.	27
2.4.3.2 Métodos de Coleta de Dados sobre Comportamento do Condutor	43
2.5 Considerações Finais	44
3. ESTUDO NATURALÍSTICO DE DIREÇÃO	46
3.1 Considerações iniciais	46
3.2 Caracterização dos estudos naturalísticos de direção	46
3.3 Aplicação de estudos naturalísticos no comportamento dos condutores de veículos	46
3.3.1 Estados Unidos	46
3.3.2 Europa	48
3.3.3 Japão	50
3.3.4 Brasil	51
3.4 Limitações dos estudos naturalísticos	52
3.5 Considerações Finais	52
4. O processo de Reamostragem	54
4.1 Erro padrão do Método bootstrap	56
4.2 Intervalos de confiança baseados no método bootstrap	56
4.3 Aplicação do bootstrap na área de Transportes	57
5. MÉTODO	60

5.1. Considerações iniciais	60
5.2 Etapas metodológicas comuns as Hipóteses.....	62
Passo 1: Comitê de Ética em Pesquisa (CEP)	63
Passo 2: Coleta de dados	63
Passo 3: Conversão da localização da estação e do condutor para UTM (Universal Transverse Mercator)	65
Passo 4: Combinação dos dados meteorológicos e de condução	66
Passo 5: Classificação das condições meteorológicas:.....	67
Passo 6: Divisão das viagens como base nas mudanças climáticas	67
Passo 7: Classificação das subviagens em Diurno ou Noturno e Pico ou entre picos.....	68
5.3 Procedimento Metodológico aplicável para análise globalizada do Comportamento dos Condutores - HIPÓTESES 1, 2 e 3:	68
A: Cálculo das porcentagens de tempo de permanência em cada faixas de velocidade, aceleração e frenagem – Hipóteses 1, 2 e 3	69
B: Identificação da quantidade de amostra por categoria investigada.....	70
C: Resultados, Análises e Discussões.....	70
- Estatísticas Descritivas	71
- Construção dos Boxplots.....	71
- Aplicação do teste de Normalidade	71
- O processo de Reamostragem	72
- Fluxograma dos Testes Estatísticos para Velocidade	74
- Fluxograma dos Testes Estatísticos para Aceleração e Frenagem	77
5.4 Procedimento Metodológico aplicável para análise individualizada do Comportamento dos Condutores - HIPÓTESES 4, 5 E 6:	79
A: Amostras	79
B: Cálculo das Velocidades	80
C: Resultados, Análises e Discussões.....	81
- Estatística Descritiva	81
- Construção dos Boxplots.....	81
- Aplicação do Teste de Normalidade	82
- Aplicação dos Paramétricos e Não Paramétricos	82
6. ESTUDO DE CASO: COMPORTAMENTO DOS CONDUTORES DE CURITIBA	
83	
6.1. Comitê de Ética em Pesquisa (CEP).....	83
6.2 Coleta de dados.....	83
6.3 Conversão da localização da estação e do condutor para UTM (Universal Transverse Mercator)	86

6.4 Combinação dos dados meteorológicos e de condução	87
6.5 Classificação das condições meteorológicas:	89
6.6 Divisão das viagens com base nas mudanças climáticas.....	89
6.7 Classificação das subviagens em Diurno ou Noturno e Pico ou Entre Picos	90
6.8. Hipóteses 1, 2 e 3:	92
A: Cálculo das porcentagens de tempo de permanência em faixas de velocidade, aceleração e frenagem	92
B: Identificação da quantidade de amostras por categoria investigada	93
C: Resultados, Análises e Discussões.....	94
6.9. Hipóteses 4, 5 e 6.....	127
A: Amostras	127
B: Cálculo das Velocidades	128
C: Resultados, Análises e Discussões.....	128
7. CONCLUSÕES	179
7.1 Limitações da Pesquisa.....	182
7.2 Recomendações para trabalhos futuros	183
REFERÊNCIAS BIBLIOGRÁFICAS	185

1. INTRODUÇÃO

A segurança viária representa elemento fundamental no planejamento e na gestão do transporte, considerando que os sinistros de trânsito se configuram como uma das principais causas de fatalidades e de prejuízos socioeconômicos. De acordo com a ONSV (2021), o Brasil contabilizou mais de 30 mil mortes no trânsito, sendo a maior parte envolvendo motociclistas (35%) e ocupantes de automóveis (22%) no ano de 2021. A taxa de mortalidade no trânsito no Brasil - 152 óbitos por 100 mil habitantes (Brasil, 2021a, 2021b) - supera a de países como Suécia (28) e Reino Unido (31) (OMS, 2018), evidenciando a necessidade de medidas eficazes para mitigação dos sinistros e aprimoramento da segurança nas vias.

A literatura classifica os fatores associados aos sinistros de trânsito em quatro domínios: humano ou comportamental, viário/ambiental e veicular (Ferraz *et al.*, 2012). Estudos realizados nos Estados Unidos e Europa indicam que a maioria dos sinistros está relacionada aos fatores humanos (65% e 57%, respectivamente) ou à combinação de humano com ambiente/via (25% e 27%, respectivamente) (Rumar, 1985; Wierwille *et al.*, 2002). Nesse sentido, um aspecto ambiental importante a ser investigado é a chuva, pois eventos climáticos adversos podem impactar a segurança viária, alterando as condições de pavimento, visibilidade e o comportamento dos condutores.

Segundo Pisano, Goodwin e Rossetti (2005), eventos climáticos afetam o comportamento dos condutores, a segurança e a mobilidade nas vias, resultando em aumento dos intervalos entre veículos, redução da tração e da velocidade operacional, maior incidência de atrasos e congestionamentos, além do aumento da capacidade da via. O impacto do congestionamento é especialmente crítico nos centros urbanos brasileiros, onde a redução da velocidade média prejudica a fluidez do tráfego (Downs, 2004; Bertini, 2005).

Além disso, a perda de visibilidade sob condições adversárias também influencia a dinâmica da condução. O Manual de Capacidade de Rodovias (HCM 2000) reforça que a principal razão para essa redução de velocidade em condições adversas é a perda de visibilidade, particularmente devido à intensidade da precipitação. Por essa razão, alguns estudos avaliam os efeitos da chuva, considerando a intensidade da precipitação (Ibrahim; Hall, 1994; Camacho *et al.*, 2010).

No Brasil, há estudos sobre comportamento dos condutores e sua relação com o ambiente viário que utilizam informações coletadas a partir da aplicação de questionários (Brasil, 2019; Ilias *et al.*, 2012), estando sujeitos ao viés da memória do respondente e sua

concepção de resposta socialmente aceitável (Dozza *et al.*, 2015). Além dos questionários, outro método utilizado para avaliação de comportamento de condutores envolve o uso de simuladores de direção. Todavia, esses equipamentos nem sempre refletem o realismo da experiência (Larocca *et al.*, 2018; Santos *et al.*, 2017).

Nesse contexto, os Estudos Naturalísticos de Direção (*Naturalistic Driving Studies – NDS*) surgem como um método mais preciso, permitindo a observação do comportamento dos condutores durante a sua rotina diária de condução, com monitoramento do interior do veículo e do ambiente externo, sem nenhum tipo de controle experimental ou influência sobre as rotas percorridas. Para isso, o veículo é equipado com uma plataforma de aquisição de dados, geralmente composta por câmeras, GPS e outros sensores, que permitem o monitoramento de uma série de variáveis associadas à condução (Van Nes *et al.*, 2019).

Estudos naturalísticos conduzidos no Brasil já analisam aspectos como o uso do celular na direção, o excesso de velocidade em vias arteriais urbanas, o efeito de radares e lombadas no comportamento dos condutores, a velocidade em diferentes tipos de curvas e o comportamento de ciclistas. No entanto, ainda não foram analisados os efeitos da precipitação, da luminosidade e volume veicular no comportamento dos condutores, sendo essa uma lacuna que este trabalho se propõe a preencher.

Dessa forma, o problema respondido nesta pesquisa é: Fatores como precipitação, luminosidade e volume veicular em diferentes períodos do dia interferem no comportamento dos condutores no que tange a velocidade, aceleração e frenagem praticadas?

1.1 Hipóteses

As hipóteses testadas nesta pesquisa estão apresentadas a seguir:

- Hipótese 1: A precipitação afeta a percentagem de tempo de permanência do condutor em cada faixa de velocidade, aceleração e frenagem investigada.
- Hipótese 2: A combinação de precipitação e luminosidade, durante o dia e a noite afeta a percentagem de tempo de permanência do condutor em cada faixa de velocidade, aceleração e frenagem investigada.
- Hipótese 3: A combinação de precipitação e o fluxo de veículos em diferentes horários, incluindo os picos e os entre picos de tráfego, afeta a percentagem de tempo de permanência do condutor em cada faixa de velocidade, aceleração e frenagem investigada.

- Hipótese 4: A precipitação afeta o desempenho individual do condutor em relação à velocidade, aceleração e frenagem?
- Hipótese 5: A combinação de precipitação e luminosidade, durante o dia e a noite afeta o desempenho individual do condutor em relação à velocidade, aceleração e frenagem?
- Hipótese 6: A combinação de precipitação e o fluxo de veículos em diferentes horários, incluindo os picos de tráfego, afeta o desempenho individual do condutor em relação à velocidade, aceleração e frenagem?

Observa-se que nas três primeiras hipóteses, o comportamento dos condutores é analisado de forma global, ou seja, não são avaliados os aspectos individuais do condutor, como experiência, estilo de direção, preferências pessoais ou outras características que possam influenciar a forma como cada motorista conduz o veículo. Embora permitam avaliar de forma global o comportamento dos motoristas em diferentes situações, não é possível analisar individualmente variações de velocidade, aceleração e frenagem, considerando o perfil de condição de cada motorista. Assim, para complementar as avaliações, nas três últimas hipóteses são comparados o comportamento de cada condutor sob diferentes condições climáticas (chuva e sem chuva), nos períodos de dia e noite e pico e entre pico, sob chuva.

1.2 Objetivo

1.2.1 Objetivo Geral

O objetivo geral desta pesquisa é analisar a influência da precipitação, da luminosidade e do volume veicular em diferentes períodos do dia no comportamento de condutores, considerando tanto a análise global quanto individualizada do desempenho dos motoristas, por meio de um estudo naturalístico de direção.

1.2.2 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Investigar se a precipitação afeta a percentagem de tempo de permanência dos condutores em cada faixa de velocidade, aceleração e frenagem.
- Determinar se a combinação de precipitação e luminosidade (dia e noite) afeta a percentagem de tempo de permanência dos condutores em cada faixa de velocidade, aceleração e frenagem.

- Analisar se a combinação de precipitação e fluxo de veículos (horários de pico e fora de pico) afeta a percentagem de tempo de permanência dos condutores em cada faixa de velocidade, aceleração e frenagem.
- Avaliar se a precipitação influencia o desempenho individual dos condutores em relação à velocidade, aceleração e frenagem.
- Verificar se a combinação de precipitação e luminosidade (dia e noite) influencia o desempenho individual dos condutores em relação à velocidade, aceleração e frenagem.
- Examinar se a combinação de precipitação e fluxo de veículos (horários de pico e fora de pico) influencia o desempenho individual dos condutores em relação à velocidade, aceleração e frenagem.

1.3 Justificativa

Os sinistros de trânsito configuram-se como uma das principais causas de mortalidade e de impactos socioeconômicos em diferentes países, apresentando elevada incidência no Brasil. Em 2023, a Agência Nacional de Transportes Terrestres (ANTT) registrou 76.637 ocorrências relacionadas ao trânsito, evidenciando a relevância de estudos direcionados à compreensão dos fatores determinantes desses eventos e ao desenvolvimento de medidas de mitigação. Nesse sentido, Brasil (2019) e Ilias *et al.* (2012) mostraram que os estudos sobre comportamento dos condutores e sua relação com o ambiente viário têm se limitado à aplicação de questionários, o que tem sua eficácia questionada por alguns estudiosos da área, pois esse tipo de análise não consegue avaliar de forma satisfatória o comportamento do condutor no momento que antecede o sinistro.

O uso de simuladores apresenta limitações, uma vez que nem sempre reproduzem com fidelidade o ambiente real de direção, o que pode comprometer a análise dos dados comportamentais. Em contrapartida, os estudos naturalísticos de direção têm se destacado como uma alternativa promissora. Essa abordagem busca eliminar as interferências artificiais ao observar o comportamento dos condutores em suas atividades diárias de direção, oferecendo uma visão mais autêntica e precisa do comportamento ao volante (Singh e Kathuria, 2021).

Do exposto, o presente estudo se justifica, pois, compreender o comportamento de motoristas quanto à velocidade, aceleração e frenagem em diferentes condições climáticas, regimes de tráfego e períodos do dia pode contribuir para a identificação de medidas a serem tomadas visando à redução de sinistros de trânsito em vias urbanas. Além disso, podem servir também de subsídio para agentes públicos no que tange à adequação da programação

semafórica em situações climáticas adversas, otimizando o fluxo e reduzindo congestionamentos nessas condições.

A adaptação da sinalização de trânsito de acordo com as condições meteorológicas é essencial para garantir a segurança dos motoristas e pedestres, além de contribuir para a melhoria da fluidez do tráfego durante períodos de chuva intensa, neblina ou outros eventos climáticos adversos. Ao compreender como os condutores reagem a essas condições e como o ambiente de direção influencia seu comportamento, os resultados deste estudo podem embasar decisões de políticas públicas e intervenções práticas, visando promover um sistema de transporte mais seguro e eficiente em áreas urbanas.

1.4 Metodologia

Para a condução deste estudo, optou-se pela adoção de uma metodologia quantitativa, explicativa e descritiva, conforme descrito por Lakatos e Marconi (2003). Este enfoque metodológico é caracterizado pelo emprego de recursos e técnicas estatísticas que facilitam a apresentação, classificação e análise dos dados por meio de valores numéricos.


Este estudo adota especificamente uma abordagem quantitativa, envolvendo a análise de dados numéricos relativos à velocidade, aceleração e frenagem dos condutores. Os dados utilizados neste trabalho foram obtidos por meio de sensores e câmeras instaladas nos veículos, o que permitiu avaliar o impacto da precipitação no comportamento dos motoristas durante a condução.

1.5 Estrutura do trabalho

Para atingir os objetivos propostos, este Trabalho de Conclusão de Curso foi estruturado em sete capítulos, organizados da seguinte forma: (i) Introdução, contemplando a contextualização do tema, a formulação do problema de pesquisa, as hipóteses, os objetivos, a justificativa e a organização do trabalho; (ii) Sinistros de Trânsito, abordando conceitos, panorama nacional e internacional e fatores associados; (iii) Estudos Naturalísticos de Direção, apresentando fundamentos, aplicações internacionais e nacionais e sua relevância no Brasil; (iv) Processo de Reamostragem/*Bootstrap*, expondo os fundamentos do método e sua aplicação na área de transportes; (v) Método, descrevendo as etapas de coleta, integração e classificação dos dados, bem como os procedimentos estatísticos utilizados; (vi) Estudo de Caso, em que o método é aplicado para analisar a influência da chuva no comportamento de condutores urbanos

em Curitiba (PR); e (vii) Resultados e Conclusões, reunindo as considerações finais, as limitações da pesquisa e recomendações para estudos futuros.

Figura 1.1 Estrutura do Trabalho



2. SINISTROS DE TRÂNSITO

2.1 Considerações iniciais

Este capítulo aborda o tema dos sinistros de trânsito, contemplando sua conceituação, panorama no Brasil e no mundo, fatores associados e comportamento dos condutores em condições climáticas adversas. São discutidos os principais fatores que contribuem para os sinistros de trânsito, com ênfase na relevância de estudos sobre comportamento dos condutores.

2.2 Contextualização de sinistros de trânsito

O conceito de trânsito adotado neste estudo segue a definição do Código de Trânsito Brasileiro (CTB), que o caracteriza, de forma geral, como a utilização das vias por pessoas, veículos e animais, isolados ou em grupos, conduzidos ou não, para fins de circulação, parada, estacionamento e operação de carga ou descarga (DENATRAN, 2011). Rozestraten (1988) complementa essa visão, afirmando que todo trânsito implica em deslocamentos de pessoas e veículos, os quais são realizados por meio de comportamentos específicos que permitem o trânsito efetivo desses elementos.

De acordo com o Código de Trânsito Brasileiro (CTB, 1997), um sinistro de trânsito é “um evento que resulta em dano ao veículo ou à sua carga e/ou em lesões a pessoas ou animais e que pode trazer dano material ou prejuízo ao trânsito, à via ou ao meio ambiente, em que pelo menos uma das partes está em movimento nas vias terrestres ou em áreas abertas ao público”. Para análise epidemiológica e de segurança viária, os sinistros normalmente são classificados conforme sua gravidade (leves, graves, fatais), natureza (colisões, atropelamentos, choques) e fatores contribuintes (humanos, veiculares, viários e ambientais) (Sun *et al.*, 2025).


2.3 Sinistros de trânsito no Brasil e no Mundo

Segundo dados da Organização Mundial da Saúde (OMS, 2018), estima-se que em 2021, ocorreram 1,19 milhão de mortes no trânsito globalmente, o que corresponde a uma taxa de 15 mortes por 100 mil habitantes. Esses números são consideravelmente superiores aos de países mais desenvolvidos e até mesmo alguns de renda média. Utilizando fontes oficiais para o cálculo, a taxa de mortes no trânsito por 100 mil habitantes no Brasil foi de 15,2 (BRASIL, 2021a, 2021b), enquanto em países como a Suécia e o Reino Unido, este valor foi de 2,8 e 3,1, respectivamente (OMS, 2018).

A Figura 2.1 mostra a distribuição das mortes no trânsito por país em termos de mortes por 100.000 habitantes em 2016. Pode-se observar que a Índia e muitos países da África Subsaariana apresentaram as maiores taxas de mortalidade no trânsito. O Brasil, por sua vez, ficou em uma faixa intermediária, com uma taxa de mortalidade entre 20 e 28 mortes por 100.000 habitantes. Esta taxa reflete a gravidade da situação no país e destaca a necessidade de medidas para a prevenção e segurança viária.

Figura 2.1 Mortes no Trânsito por País

Road Deaths by Country / 100,000 Population 2016



Fonte: *Rhino car hire*, 2016.

A OMS prevê que a situação tende a se agravar nos próximos anos, particularmente nos países de baixa e média renda, devido ao crescimento contínuo na quantidade de veículos e à insuficiência de planejamento e investimento na infraestrutura viária.

No Brasil, os sinistros de trânsito estão entre as principais causas de mortes não naturais, com uma taxa de mortalidade de 15,2 mortes por 100.000 habitantes, número alinhado à média global, mas significativamente mais alto do que em países desenvolvidos (Brasil, 2021). Nesse sentido, a análise dos fatores de risco associados aos sinistros de trânsito tem sido amplamente abordada na literatura científica (Rios, *et al.* 2020; Bazílio, *et al.* 2022; Zhang *et al.*, 2023).

2.4 Fatores associados aos sinistros de trânsito


Autores como Ferraz *et al.* (2012) e Sun *et al.* (2025) mencionam que os sinistros de trânsito são influenciados por fatores como comportamento humano, características dos

veículos, das vias e do ambiente, além de aspectos institucionais, como legislação e fiscalização. A literatura aborda esses fatores de diversas maneiras, mas, de modo geral, eles podem ser agrupados em três categorias principais:

- a) Fatores humanos/usuário;
- b) Fatores da via/veículo;
- c) Fatores ambientais.

A Figura 2.2 ilustra de forma esquemática as interações entre diferentes fatores que influenciam nos sinistros de trânsito, conforme citados acima. Da análise da referida figura observa-se a sobreposição de áreas, o que indica que muitos sinistros são consequência da interação entre múltiplos fatores. Por exemplo, um comportamento de risco do motorista (fator humano) pode ser agravado por condições climáticas adversas (fator ambiental) e por uma via mal sinalizada (fator da via/veículo). Assim, destaca a importância de considerar uma abordagem realista na análise e prevenção de sinistros de trânsito.

Figura 2.2 Diagrama esquemático das relações de trânsito



Nesse sentido, vários autores têm estudado sobre a influência de cada um desses fatores isoladamente, bem como a combinação dos fatores humanos/usuário, via/veículo e ambientais. O estudo de Thomazi (2018), por exemplo, observou que a maioria dos sinistros de trânsito ocorre devido a fatores humanos, seguidos pela interação entre elementos humanos e viários/ambientais. Hoffmann *et al.* (2003) constataram que os fatores ambientais também contribuem para os sinistros de trânsito, pois as condições das vias orientam os condutores sobre permissões, restrições, obrigações e proibições.

Rozestraten (1988) destacou que o ser humano é o elemento mais importante para a segurança do trânsito, pois controla o veículo e interage com a via. Estudos posteriores, incluindo os de Rozestraten e Dotta (1996), revelaram que mais de 90% dos sinistros de trânsito estavam relacionados a fatores humanos, enquanto apenas 10% eram atribuídos a condições

ambientais, da via ou do veículo com base em análise de pesquisas realizadas entre 1970 e 1977, em uma amostra de 1.066 acidentes. Essas conclusões são corroboradas pelo relatório da NHTSA (2017), nos Estados Unidos que constatou que o comportamento humano permanece como a principal causa de mortes no trânsito. Em 2016, por exemplo, 28% das fatalidades estavam associadas à condução sob efeito de álcool, 27% ao não uso do cinto de segurança, e 27% ao excesso de velocidade. Além disso, 48% das vítimas fatais em veículos de passageiros não utilizavam o cinto no momento da colisão. Esse relatório ainda menciona que escolhas humanas, tais como a não observância de dispositivos de segurança, a direção imprudente e o consumo de substâncias, continuam sendo os principais fatores de risco de sinistros de trânsito.

A probabilidade de ocorrência de um sinistro viário aumenta proporcionalmente à quantidade de fatores de risco envolvidos que atuam de forma simultânea. Esses fatores podem incluir eventos aleatórios, falhas no projeto geométrico das vias ou comportamento imprudente por parte dos usuários da via. Conforme destacado por Elvik *et al.* (2009), quanto maior o número de fatores conhecidos e analisados, maior é a capacidade preditiva dos modelos de avaliação de risco, pois isso permite a obtenção de estimativas mais precisas da frequência e gravidade dos sinistros. Devido à importância dos fatores humanos/usuário, via/veículo e ambientais no comportamento dos motoristas, a seguir, são apresentados estudos que tratam de cada um deles.

2.4.1 Fatores humanos

Para compreender as causas dos sinistros de trânsito, é fundamental analisar a influência de fatores humanos no comportamento dos usuários das vias. Nesse contexto, diversos autores identificaram condutas e características individuais associadas à ocorrência destes eventos, entre elas, destaca-se:

Emprego de velocidade inapropriada: refere-se à adoção de velocidade incompatíveis com as condições da via, do tráfego e do ambiente, podendo ser tanto excessiva quanto inadequadamente reduzida. Todavia, a velocidade excessiva é mais crítica, pois compromete o tempo de reação do condutor e agrava a severidade dos impactos (Etika, *et al* 2023). O excesso de velocidade contribui para cerca de 30% dos sinistros de trânsito nos países de alta renda e 50% nos países de baixa e média renda (Who, 2009).

Desvio de atenção: consiste na perda momentânea de atenção ao trânsito e normalmente estão associadas ao uso de telefone celular, a busca de objetos no interior do veículo e outros

estímulos concorrentes que comprometem a atenção às demandas ao dirigir. Estudos indicam que, em cerca de 15% dos sinistros de trânsito, o desvio da atenção dos condutores foi o fator principal (WHO, 2009). Bucsuházy *et al.* (2020) demonstraram que a falta de atenção influenciou em 40% dos acidentes analisados na base de dados do *Czech In-depth Accident Study* (CzIDAS) da República Tcheca. Conforme o referido estudo, isso pode decorrer de diversos fatores: sobrecarga cognitiva (35%), distrações específicas (19%) e condução monótona (13%), entre outros.

Ingestão de álcool, drogas ou medicamentos: O consumo de álcool, drogas ou medicamentos apresenta riscos no trânsito, pois a ingestão dessas substâncias pode prejudicar a capacidade de condução, afetando a percepção, o julgamento e o tempo de reação do motorista (Who, 2009). Vrabel *et al.* (2020) demonstraram que o tempo de reação dos condutores quase dobra quando o teor alcoólico ultrapassa 1,5 ‰ no hálito do motorista. No Brasil, a Resolução CONTRAN nº 432, de 23 de janeiro de 2013, permite que os agentes da Autoridade de Trânsito identifiquem sinais de alteração na capacidade psicomotora dos condutores, considerando aspectos como aparência, atitudes, orientação, memória, e habilidades motoras e verbais.

Falhas físicas ou psicológicas: Incluem situações como adormecimento ao volante, ataques cardíacos, fadiga ou estados emocionais alterados. Um estudo realizado na Nova Zelândia revelou que o número de sinistros de trânsito poderia ser reduzido em até 19% se as pessoas evitassem dirigir sob as seguintes condições: sensação de sonolência, entre 2 e 5 horas da madrugada, e após terem dormido menos de 5 horas nas últimas 24 horas (Connor *et al.*, 2002). Outro estudo realizado nos Estados Unidos identificou que 4% dos motoristas relataram ter adormecido ao volante nos últimos 30 dias, com a prevalência mais alta entre homens jovens e motoristas que dormem menos de 5 horas por noite (Wheaton *et al.*, 2014). Ademais, o relatório da NHTSA (2017) reforça esse problema ao estimar que 7% de todos os acidentes e 16,5% dos acidentes fatais nos Estados Unidos envolvem motoristas sonolentos. Isso corresponderia a aproximadamente 6.000 mortes anuais, embora especialistas considerem esse número subestimado.

Falha na interpretação da situação: ocorre quando condutores ou pedestres cometem erros ao julgar a sequência Percepção, Identificação, Emoção e Reação (PIEV), ou ao prever incorretamente as ações dos outros atores envolvidos no trânsito. Homburger (2003) descreveu esse processo em quatro etapas:

1. Percepção (Perception): momento em que o motorista visualiza um objeto na rodovia ou um sinal de alerta.
2. Identificação (Identification): fase em que o objeto percebido na etapa anterior é identificado.
3. Tomada de decisão (Emotion): o condutor decide qual ação tomar, como pisar no freio, mudar de faixa, desviar do objeto ou cruzar a interseção.
4. Reação (Volition): etapa em que o motorista executa a ação decidida na fase anterior.

Estudos indicam que condutores inexperientes tendem a adotar comportamentos de direção mais arriscados, como dirigir em alta velocidade e manter uma distância inadequada em relação ao veículo à frente, em comparação com motoristas experientes (Mayhew e Simpson, 2003). Como resultado, eles estão mais suscetíveis a se envolver em situações potencialmente perigosas. Nesse sentido, o estudo DRIVE, realizado na Austrália com mais de 20 mil motoristas novatos, demonstrou que comportamentos de direção de risco estão associados ao aumento da probabilidade de acidentes. Motoristas que relataram maior frequência desses comportamentos apresentaram um risco 50% superior de se envolver em colisões, mesmo após ajuste para diversos fatores de confusão (Ivers *et al.*, 2009). Além disso, devido à falta de habilidade e experiência, os motoristas novatos têm menor capacidade de lidar de maneira eficaz com esses cenários de risco, o que aumenta sua vulnerabilidade no trânsito. De acordo com Harré (2000), em situação de alto risco, aqueles motoristas que subestimam o risco, percebendo-o como baixo, tendem a adotar um comportamento mais imprudente ao volante, enquanto os percebem o perigo como elevado tendem a dirigir com cautela, adotando medidas para evitar riscos.

2.4.2 Fatores da via/veículo

Problemas relacionados às condições da via podem contribuir para a ocorrência de sinistros. Superfícies irregulares, como buracos, sulcos trincas e depressões, além de drenagem deficiente e pista escorregadia, podem levar à perda de controle do veículo, especialmente durante desvios de buracos ou em situações de aquaplanagem devido ao acúmulo de água sobre a pista. Além disso, projetos geométricos inadequados, como curvas de pequeno raio após longos trechos retos e trechos com visibilidade insuficiente, aumentam o risco de sinistros (Brasil, 2023).

No que diz respeito aos veículos, a presença de dispositivos de segurança ativa e passiva tem demonstrado impacto significativo na redução de lesões e mortes. Sistemas como ABS, airbags frontais e laterais, controle eletrônico de estabilidade (ESC), freios autônomos de emergência (AEB) e cintos de três pontas reduzem o risco de colisões graves. Nesse sentido, dados da *National Highway Traffic Safety Administration* indicam que o uso combinado de cintos de segurança e airbags pode reduzir em até 61% o risco de morte em colisões frontais (Bean *et al.*, 2009).

No contexto brasileiro, a Polícia Rodoviária Federal, com base em dados do ano de 2022,) apontou que a manutenção inadequada dos veículos foi responsável por 6,81% dos sinistros nas rodovias federais (Brasil, 2023). Entre as deficiências veiculares observadas tem-se: desgaste excessivo dos pneus, falhas no sistema de iluminação, faróis desregulados, problemas nos freios e suspensão e falhas elétricas ou mecânicas.

2.4.3 Fatores Ambientais

Fatores climáticos, como chuva e neblina, têm influência na ocorrência de sinistros de trânsito, uma vez que podem reduzir a visibilidade, diminuir a aderência dos pneus com o pavimento e aumentar as distâncias de frenagem. Nesse sentido, o estudo conduzido por Song *et al.* (2023) na China destacou que a taxa de sinistros causados por neblina em autoestradas é 2,5 vezes maior do que a causada por outros eventos meteorológicos severos, sendo responsáveis por 29,5% do total de vítimas em sinistros de trânsito.

Qiu e Nixon (2008) também constataram, a partir de meta-análise de 34 estudos realizados entre os anos de 1967 e 2005, que a precipitação (chuva ou neve) aumenta a taxa de sinistros em 71 % a 84 %, embora possa reduzir a gravidade dos acidentes em alguns casos.

Fatores ambientais, como chuva, neblina, gelo e outras condições adversas, têm uma influência na ocorrência de sinistros de trânsito. Essas condições reduzem a visibilidade e a aderência dos pneus à superfície da via, aumentando o risco de acidentes. As primeiras gotas de chuva, especialmente, tornam a pista mais escorregadia, elevando o perigo de perda de controle do veículo (Ferraz *et al.*, 2010).

O próximo item traz estudos científicos sobre o comportamento de condutores sob diferentes condições climáticas, de visibilidade (dia/noite) e horários (pico/entre picos). O objetivo é compreender como os motoristas ajustam (ou deixam de ajustar) seu comportamento

às limitações impostas pelo ambiente, considerando variáveis como velocidade, aceleração e frenagens.

2.4.3.1 Estudos sob Comportamento dos condutores em condições climáticas adversas.

Na literatura, pode-se encontrar uma série de estudos que abordam a influência da precipitação no comportamento dos motoristas. Eles geralmente investigam como a chuva impacta o comportamento dos condutores, incluindo velocidade, visibilidade (dia e noite), horário das viagens (pico e entre picos), acelerações e frenagens.

Nesse sentido, Elyoussoufi *et al.* (2023) analisaram a relação entre condições meteorológicas adversas e o comportamento dos motoristas, utilizando dados de 2019 da rodovia Colorado Highway 119 (EUA). As condições climáticas foram classificadas em três tipos: céu limpo, chuva e neve. Os autores constataram uma redução na velocidade média nos dias chuvosos (redução entre 0,3% e 2%) e de forma mais acentuada nos dias de neve (redução de até 8,3% nas manhãs de dias úteis). A menor velocidade média foi observada no pico da manhã em dias de neve: 26,4 mph (42,6 km/h), contra 28,8 mph (46,4 km/h) sem precipitação. Segundo os autores, essa redução na velocidade é consequência do comportamento adaptativo dos condutores, que tendem a ajustar sua condução diante do aumento do risco percebido, especialmente em função da visibilidade reduzida e da ampliação das distâncias de frenagem. Dessa forma, os motoristas ajustam sua condução em resposta ao risco percebido, evidenciando uma compensação comportamental frente às condições adversas da via.

O estudo de Faria *et al.* (2020), realizado na Região Metropolitana de Lisboa – Portugal, monitorou o comportamento de 47 motoristas entre 2013 e 2015 por meio de dispositivos de coleta de dados instalados em seus veículos. Em situações de tempo seco, os motoristas permaneceram, em média, 1,5% do tempo em acelerações classificadas como bruscas, e 1,7% em frenagens igualmente abruptas. Já sob condições de chuva, esses valores aumentaram para 2% e 3,5%, respectivamente. Tais percentuais se referem exclusivamente à fração do tempo de condução em que os veículos apresentaram valores de aceleração ou desaceleração longitudinal iguais ou superiores a $2,5 \text{ m/s}^2$. A intensificação dos episódios de aceleração e frenagem bruscas foi interpretada pelos autores como um indicativo de maior instabilidade operacional em cenários meteorológicos adversos. Segundo sua análise, fatores como a redução da aderência do pavimento, a diminuição da visibilidade e o aumento da complexidade perceptiva do ambiente viário em dias chuvosos elevam a necessidade de correções mais frequentes e abruptas

por parte dos condutores. Isso, por sua vez, pode aumentar a variabilidade comportamental e o risco de incidentes, especialmente em áreas urbanas densas.

Esse mesmo estudo ainda constatou que durante chuvas intensas, houve uma redução de 22% na velocidade média em comparação com condições secas, além de uma diminuição de 8% nas acelerações e 11% nas frenagens. No entanto, a frequência de frenagens e acelerações bruscas não alteraram significativas entre motoristas mais experientes em condução sob chuva, sugerindo que a habituação às condições chuvosas pode reduzir a percepção de risco e minimizar ajustes no comportamento de direção (Faria *et al.* 2020).

No que tange à intensidade da chuva, Sakhare *et al.* (2023), analisaram 275.422 registros de velocidade coletados entre janeiro e outubro de 2021, de uma rodovia em Indiana (EUA), integrando essas informações com dados pluviométricos de estações próximas. Os resultados revelaram uma redução na velocidade média dos veículos conforme aumentava a intensidade da chuva. Em relação à condição seca, observou-se uma diminuição média de 1,93% sob chuva leve (0 a 0,5 mm/h), 4,19% sob chuva moderada (0,5 a 4 mm/h), 5,04% sob chuva forte (4 a 8 mm/h) e 8,40% sob chuva muito intensa (>8 mm/h). A maior redução absoluta registrada foi de 5,61 mph (9,03 km/h) durante episódios de chuva muito intensa. Esse estudo também identificou um aumento na dispersão das velocidades, com o intervalo interquartil (IQR) passando de 8,34 mph (tempo seco) para 10,18 mph (chuva forte).

Os autores argumentaram que a intensidade da chuva atua como um moderador comportamental, levando condutores a reduzir a velocidade e, possivelmente, aumentar a distância de seguimento em resposta à diminuição da visibilidade e à perda de aderência da pista. O estudo ainda destacou que, embora a média agregada de velocidade reduza com a chuva, a magnitude da mudança pode não ser suficiente para compensar o aumento do risco de acidentes, especialmente quando a intensidade pluviométrica é elevada (Sakhare *et al.*, 2023).

Agarwal *et al.* (2006) avalizaram os impactos das condições climáticas (sem chuva, neblina (menor que 0,25 mm/h), chuva leve (entre 0,25 e 6,35 mm/h) e chuva intensa (maior que 6,35 mm/h)) no desempenho operacional de segmentos rodoviários localizados na região metropolitana de *Twin Cities* (Minnesota-EUA), utilizando dados de tráfego coletados ao longo de quatro anos por meio de laços magnéticos. Os resultados indicaram que a capacidade viária foi reduzida em 1 a 3% para chuvas leves, 5 a 10% para chuvas moderadas e 10 a 17% para chuvas intensas. Além disso, a velocidade de tráfego apresentou reduções entre 1% e 7% à medida que a precipitação se intensificava. No entanto, a diferença na velocidade média entre

chuvas leves e intensas não foi estatisticamente significativa, sugerindo que o comportamento dos condutores está mais associado à presença ou ausência de chuva do que à sua intensidade.

O estudo de Sundström (2011) analisou a evolução da percepção de risco e do comportamento de velocidade de motoristas ao longo do tempo, com base em um experimento longitudinal realizado em simulador de direção. Trinta participantes foram expostos a cenários desafiadores em três sessões distintas ao longo de um período de aproximadamente um ano. Os resultados encontrados indicam que os condutores, em média, reduziram sua velocidade em apenas 2 km/h ao longo do tempo, apesar das repetições e do aumento da familiaridade com os cenários de risco. A velocidade média no primeiro teste foi de 74 km/h, diminuindo para 72 km/h na última sessão, o que representa uma mudança relativamente modesta. A percepção subjetiva de risco permaneceu praticamente inalterada, com escores médios de 3,6 na escala *Likert* (1 a 5), indicando que os participantes continuaram se considerando condutores seguros e pouco vulneráveis.

Segundo a autora, esses resultados são reflexo da tendência dos motoristas a superestimar suas próprias habilidades, o que reduz a sensibilidade a intervenções baseadas apenas na experiência direta. Essa autoconfiança excessiva pode comprometer a adoção de estratégias de mitigação de risco, como a redução da velocidade em condições adversas. Sundström (2011) conclui que, para modificar comportamentos arraigados, especialmente entre motoristas experientes, são necessárias abordagens personalizadas que combinem feedback individualizado e estratégias cognitivas voltadas à conscientização do risco.

Adicionalmente, Smith *et al.* (2004) analisaram o efeito da precipitação na intensidade do tráfego em Hampton Roads, Virgínia e constataram que a capacidade da rodovia é reduzida em uma faixa de 4% a 10% durante chuvas leves (intensidade de 0,01 a 6,35 mm/h) e em uma faixa de 25% a 30% durante chuvas fortes (intensidade superior a 6,35 mm/h).

Billot *et al.* (2009) investigaram os efeitos da chuva no comportamento dos condutores e nas condições operacionais do tráfego utilizando dados de tráfego coletados por sensores de laço duplo de uma rodovia interurbana na França, integrados a informações meteorológicas localizadas. No nível microscópico, o estudo constatou que os condutores reduzem sua velocidade e aumentam o espaçamento e os intervalos de tempo entre veículos sob chuva. Todavia, com a intensificação da chuva, houve redução significativa nas frequências de velocidades muito altas ou muito baixas, com aumento na frequência de velocidades intermediárias. Por exemplo, a proporção de veículos com velocidades entre 70 e 90 km/h

passou de 35% em condição seca para 53% sob chuva moderada, enquanto a frequência de velocidades superiores a 110 km/h foi reduzida. Essa redistribuição nas faixas de velocidade foi interpretada pelos autores como uma adaptação dos condutores ao risco percebido nas condições úmidas, o que leva à concentração do tráfego em uma faixa mais estável de velocidades operacionais. Ainda no nível micro, houve redução de 18% nos intervalos de tempo inferiores a 2 segundos e um aumento correspondente nos intervalos entre 2 e 10 segundos, indicando maior cautela por parte dos motoristas em cenários chuvosos.

Chen *et al.* (2019) investigaram como condições meteorológicas adversas afetam a percepção de risco dos condutores durante situações de acompanhamento veicular (car-following), por meio de simulações controladas em ambiente virtual. O estudo avaliou 11 cenários climáticos (incluindo diferentes intensidades de chuva, neve e neblina) e três tipos de segmentos viários (plano, aclive e declive). Os resultados mostraram que a percepção de risco aumenta à medida em que as condições climáticas se agravam, especialmente sob chuva ou neve intensas. Isso leva os condutores a adotarem comportamentos adaptativos, como reduzir a velocidade e aumentar a distância de seguimento. Todavia, essa redução não implica, necessariamente, na adoção de velocidades extremamente baixas. Ao contrário, os motoristas tendem a buscar velocidades moderadas e controladas, com acelerações e desacelerações mais suaves, de modo a equilibrar fluidez e segurança (Chen *et al.*, 2019).

Rahman e Lownes (2018) utilizaram dados do *SHRP 2 Naturalistic Driving Study* (SHRP 2 NDS) para avaliar o comportamento dos motoristas sob diferentes condições climáticas. Os autores constataram que os motoristas adotam uma postura mais cautelosa sob chuva leve ou intensa, ajustando a velocidade e aumentando o espaçamento entre veículos. Em pista seca, a velocidade média foi de 45,1 mph (72,6 km/h), enquanto sob chuva leve reduziu para 42,4 mph (68,2 km/h) e sob chuva intensa diminuiu para 41,4 mph (66,6 km/h). Embora a redução absoluta pareça modesta, essas diferenças foram estatisticamente significativas ($p < 0,05$), e geram ajustes conscientes dos condutores para compensar o aumento da percepção de risco. Além disso, foi observado um aumento na distância de seguimento e uma redução no número de eventos de frenagem brusca, sugerindo um comportamento de condução mais estável e defensivo.

Estudo realizado na China, por Ni *et al.* (2022), utilizando um simulador de direção, avaliou o comportamento de 47 motoristas, testando 30 cenários diferentes com variações nas condições de chuva e nos níveis de água acumulada na pista (alagamento de 5, 10 e 15 cm). O estudo constatou que a presença simultânea de chuva intensa e alagamento afeta

significativamente o desempenho na condução, mais do que quando essas condições ocorrem isoladamente. A velocidade média dos motoristas reduziu, sob condições mais severas, em até 35,7%, e a aceleração longitudinal média reduziu entre 15,2% e 10,8%, dependendo da profundidade da água. Os autores justificaram esses efeitos com base na complexidade operacional e na elevação da percepção de risco em cenários com chuva intensa e alagamento, uma vez que a visibilidade reduzida, a incerteza quanto à profundidade da água e a menor aderência do pavimento levam os condutores a adotarem uma condução mais cautelosa. Além disso, observou-se que, embora o desempenho geral tenha sido impactado, não houve aumento expressivo na frequência de acelerações abruptas, sugerindo que os motoristas tenderam a suavizar suas respostas, priorizando a manutenção da estabilidade do veículo conforme o risco percebido.

Bakhshi *et al* (2022) conduziram um estudo com 680 condutores da cidade de Qom, (Irã), a fim de avaliar os efeitos da chuva sobre diferentes dimensões do comportamento de condução. Foram definidas quatro dimensões de comportamento: (i) alta velocidade com violação de leis, (ii) erros operacionais, (iii) comportamento positivo e cauteloso e (iv) comportamento agressivo. Dentre essas categorias, a mais sensível à presença de chuva foi a de “alta velocidade com violação de leis”, que apresentou uma redução média de 8,91% no comportamento relatado. A tendência de ultrapassar pela direita reduziu em 13%, e o desrespeito ao limite de velocidade em rodovias diminuiu 6% em comparação com o tempo seco. Os autores justificaram esses resultados com base no aumento da percepção de risco provocado pelas condições adversas de visibilidade e aderência do pavimento, levando os motoristas a adotarem uma condução mais conservadora. Além disso, observou-se uma redução de até 3,92% nos comportamentos agressivos durante a condução em chuva, sendo o uso da buzina para expressar raiva o item mais impactado. Todavia, comportamentos positivos e cautelosos aumentaram, em média, 3,5% nas condições chuvosas.

Fatores sociodemográficos também se mostraram relevantes na modulação do comportamento dos condutores em condições climáticas adversas. Motoristas do sexo feminino apresentaram menor envolvimento com comportamentos de risco tanto em tempo seco quanto chuvoso, com redução nos escores médios de comportamento agressivo de 1,63 para 1,55, respectivamente. Entre os homens, os escores foram superiores em ambas as condições (1,94 no tempo seco e 1,82 sob chuva), evidenciando uma maior propensão ao risco. Condutores jovens (menores de 25 anos), por sua vez, não apresentaram alterações significativas em seus padrões de direção, mantendo escores praticamente estáveis (2,31 no tempo seco e 2,33 sob

chuva), o que sugere menor sensibilidade às mudanças nas condições operacionais. Em contraste, motoristas com mais de 10 anos de experiência na direção apresentaram uma redução expressiva nos comportamentos agressivos, com seus escores caindo de 1,92 para 1,60. Tendência semelhante foi observada entre condutores casados (1,89 para 1,59) e aqueles com nível superior de escolaridade (1,88 para 1,58), reforçando a influência de variáveis pessoais no ajuste comportamental diante da chuva (Bakhshi *et al.*, 2022).

Yang *et al.* (2021) avaliaram como as mudanças climáticas, especialmente a chuva, afetam o congestionamento do tráfego em Jacarta, na Indonésia. Por meio de dados reais coletados de sensores de smartphones, informações meteorológicas em tempo real e características das vias, os pesquisadores propuseram uma matriz de velocidade de congestionamento espaço-temporal (STC) para ilustrar as variações de velocidade do tráfego ao longo do tempo. A partir dessa matriz, aplicaram um framework de clustering e classificação sequencial para identificar as vias sensíveis às condições climáticas (WSR) em termos de velocidade do tráfego.

Estudo realizado por Liu *et al.* (2017), revelou que condições climáticas extremas, como tempestades, aumentam o risco de sinistros devido ao impacto nas condições da via e na capacidade de resposta dos motoristas. Os pesquisadores constataram que a velocidade de fluxo livre diminui entre 0,3% e 5% sob chuva leve, 5,1% e 7,4% sob chuva moderada, 4,6% e 8,2% sob chuva forte e 9,8% e 13,3% sob chuva torrencial, especialmente em segmentos com apenas duas faixas de tráfego, onde a visão e o julgamento dos motoristas são mais afetados.

Os estudos de Billot *et al.* (2009), Camacho *et al.* (2010) e Hou *et al.* (2013) investigaram a influência da precipitação na Velocidade de Fluxo Livre (VFL) e no comportamento dos condutores em diferentes condições climáticas. Billot *et al.* (2009) analisou o impacto de diferentes intensidades de precipitação no tráfego urbano em Paris, França. Os resultados demonstraram que chuvas leves (2–3 mm/h) reduziram a VFL em 8%, enquanto chuvas moderadas a intensas resultaram em uma redução de 12,6%. Esses dados sugerem que os condutores ajustam sua velocidade de forma proporcional à severidade da precipitação, evidenciando um comportamento adaptativo frente às condições adversas da via.

Nesse mesmo contexto, Camacho *et al.* (2010) avaliaram como condições meteorológicas adversas influenciam a velocidade de fluxo livre em rodovias espanholas. Foram selecionados quinze trechos de rodovias no noroeste da Espanha. Para tal, coletou-se dados de tráfego e condições climáticas de um período de quase três anos (2006 a 2008). A

pesquisa demonstrou que a presença de chuva provocou uma redução estatisticamente significativa na velocidade de fluxo livre dos veículos. Em média, observou-se uma diminuição de aproximadamente 5% a 10% na velocidade sob chuva leve, podendo alcançar até 15% em situações de chuva intensa. A perda de visibilidade apresentou um efeito logarítmico na redução da velocidade, indicando que, quando a visibilidade começa a diminuir, a velocidade dos motoristas reduz rapidamente nos primeiros estágios da redução de visibilidade. No entanto, à medida que a visibilidade continua diminuindo, a taxa de redução da velocidade torna-se menos acentuada.

Os autores justificam essa redução da velocidade como uma resposta dos condutores ao aumento do risco percebido, atribuído à diminuição da aderência do pavimento e à piora nas condições de visibilidade. Além disso, destacou-se que as reduções foram mais pronunciadas em trechos com maior declividade e menor visibilidade horizontal, sugerindo que o ambiente viário também modula o impacto da chuva sobre o comportamento dos motoristas.

Hou *et al.* (2013) avaliaram o efeito da chuva na VFL em diversas cidades dos Estados Unidos, incluindo Irvine, Chicago, Salt Lake City e Baltimore. Os resultados apontaram variações na redução da velocidade em função da intensidade da precipitação. Em Irvine, por exemplo, chuvas leves ($<2,5$ mm/h) causaram uma diminuição de 6,13% na VFL, enquanto chuvas moderadas (2,5–7,5 mm/h) resultaram em uma queda de 11,38% e chuvas intensas ($>7,5$ mm/h) reduziram a VFL em 18,60%. Resultados similares foram observados em outras cidades analisadas, confirmando que a intensidade da precipitação influencia a velocidade média dos condutores. Dos estudos que investigaram a relação entre a VFL e a precipitação, observa-se que ambos indicaram que as condições meteorológicas adversas impactam a dinâmica do tráfego, sendo essencial considerar esses fatores no planejamento viário e em modelos preditivos de fluxo de tráfego.

Rakha *et al.* (2008) quantificaram os impactos do clima no comportamento do tráfego por meio da avaliação da VFL. A amostra contemplou dados meteorológicos (precipitação e visibilidade) e de detectores de loop (velocidade, fluxo e densidade) localizados nas regiões metropolitanas de três áreas dos Estados Unidos, sendo elas: Baltimore, Minneapolis/St. Paul e Seattle. A pesquisa avaliou informações referentes aos dois anos com os maiores índices de precipitações para cada região, considerando o período entre 2002 e 2004. Os autores concluíram que, para chuvas leves (menor que 0,25 mm/h), houve diminuição entre 2 e 3,6% na VFL e para chuvas intensas (maior que 6,4 mm/h), a redução atingiu o nível máximo de 9%,

indicando que houve influência dos níveis de intensidade pluviométrica na VFL desenvolvida para as três áreas estudadas.

Hranac *et al.* (2006) também avaliaram a influência da chuva na velocidade dos veículos nos Estados Unidos. Segundo o estudo, a velocidade média do fluxo livre pode ser reduzida de 10% a 25% sob condições de chuva moderada a intensa, e o impacto varia conforme a intensidade da precipitação. Como consequência, essa redução implica em um aumento proporcional no percentual de tempo que os motoristas passam em faixas de velocidade mais baixas, uma vez que a transição para velocidades superiores ocorre de forma mais lenta ou é limitada pelas condições da via e do tráfego.

Nesse mesmo sentido, Van Ommeren e Dargay (2006) analisaram 42.534 viagens por automóveis na Holanda, a fim de investigar a relação entre velocidade, percepção de risco e mudanças climáticas. Para tal, foi utilizada a teoria da Compensação de Risco “*Risk Compensation*”. Os autores concluíram que os motoristas ajustam suas velocidades conforme sua percepção de risco, realizando mudanças graduais na distribuição do tempo de permanência entre faixas de velocidade. Assim, em cenários de chuva, a transição para faixas intermediárias pode refletir uma tentativa de compensação entre segurança e eficiência na condução.

A Compensação de Risco consiste em ajustes na velocidade por parte do condutor, conforme sua percepção de risco. Nesse contexto, Ali, Ahmed e Yang, (2021). identificaram que, embora os motoristas reduzam a velocidade durante a chuva, o aumento da velocidade após a precipitação tende a ser abrupto, muitas vezes ignorando os riscos associados à pista ainda molhada. Além disso, os referidos autores observaram que os comportamentos de condução são mais arriscados em condições de chuva do que em tempo seco e tendem a persistir por mais tempo, aumentando a probabilidade de sinistros.

Outro conceito encontrado na literatura que trata da relação entre velocidade e condições adversas como a chuva é o Efeito de Retorno da Velocidade (*Speed Rebound Effect*) evidenciado por Sabir (2011). Segundo o referido autor, os motoristas tendem a retomar suas velocidades originais logo após o fim da chuva, alguns adotam velocidades superiores após eventos climáticos adversos, buscando recuperar tempo de viagem ou simplesmente ajustando-se à melhora da aderência e visibilidade.

Karlaftis e Yannis (2010) observaram, para a região de Atenas, na Grécia, que durante as precipitações, os condutores tendem a assumir um comportamento mais cuidadoso, isto

porque na região o índice de precipitação é bastante reduzido. Desta forma, os condutores tomam mais cuidado, por não apresentarem costume de dirigir na chuva.

Stamos *et al* (2016) avaliaram os efeitos de chuvas na velocidade dos veículos em Tessalônica, Grécia, a partir do estudo do comportamento de condução de 1.200 táxis que continham coordenadas de GPS e informações de velocidade referentes ao ano de 2014. Os resultados revelaram que os percentuais de reduções de velocidade dos veículos aumentam com a intensidade da precipitação de forma não linear. A precipitação leve (0,25 mm/h a 1 mm/h) reduziu a velocidade do veículo na faixa de 1,5% a 3,3%. Para a intensidade moderada de chuva, houve um impacto de 8,9% a 19,2%, enquanto a chuva forte afetou a velocidade do veículo em 4,2% a 28,3%. Além disso, os autores concluíram que a redução da velocidade não ocorre de maneira uniforme em todas as vias, sendo mais pronunciada nas arteriais principais do que nas vias locais e secundárias. Nas vias arteriais principais, reduções significativas foram observadas mesmo para precipitações leves, enquanto, as vias secundárias e locais, a redução de velocidade foi menos expressiva e, em alguns casos, mínima. Isso sugere que, em rodovias de maior porte, os motoristas são mais sensíveis às condições climáticas adversas, possivelmente devido a velocidades operacionais mais altas e maior percepção de risco.

No Brasil, estudo realizado na cidade de Fortaleza por Moreira (2018), com objetivo de analisar como condições climáticas adversas, especialmente a chuva, influenciam o comportamento dos condutores em vias urbanas. A amostra foi obtida de 274 radares fixos dispersos na referida cidade. O estudo constatou que evidências estatisticamente significativas de que a intensidade da chuva influencia as velocidades desenvolvidas em ambiente urbano. Houve redução de até 3,38 km/h, aproximadamente, 6% entre as médias da situação seca para a de chuva mais intensa. Esse estudo constatou que a chuva tem influência sobre o comportamento de condução do motorista, entretanto, essa redução não foi elevada. O autor justifica isso, alegando que o estudo foi conduzido em ambiente urbano, onde as características das vias e do tráfego não oferecem condições suficientes para o desenvolvimento de velocidades mais altas. Todavia, os resultados encontrados foram próximos aos obtidos por Agarwal *et al.* (2006) (redução entre 1 e 7%) e por Rakha *et al.* (2008) (2 a 9% de redução na VFL para chuvas intensas).

Rahman e Lownes (2012) conduziram um estudo nos Estados Unidos para avaliar os impactos da chuva na velocidade e espaçamento de veículos em rodovias. Os autores analisaram dados observacionais de veículos trafegando em condições de tempo seco e chuvoso, utilizando modelos estatísticos para comparar os padrões de condução. Os resultados indicaram que, em

média, a chuva leve provocou uma redução de 4,6% na velocidade dos veículos em rodovias e 7,2% em vias arteriais urbanas. Em cenários de chuva moderada a forte, a redução atingiu 10,5% em rodovias e 13,8% em vias urbanas. Os autores justificam esses resultados com base na percepção de risco elevada por parte dos condutores, especialmente em vias com maior interferência urbana, onde a visibilidade e o atrito com o pavimento se tornam críticos. Além disso, observou-se um aumento nos tempos médios de viagem, variando de 6% a 14% dependendo da intensidade da chuva e do tipo de via analisada, enquanto a distância entre veículos permanecia praticamente inalterada.

O estudo de Sathiaraj *et al.* (2018) avaliou o impacto de variáveis meteorológicas, como precipitação, temperatura, visibilidade e velocidade do vento, no volume de tráfego horário em dias úteis na cidade de Atlanta, Geórgia/EUA. A amostra investigada foi obtida de 48 Registradores Automáticos de Tráfego (ATR) e as informações climáticas foram obtidas de quatro estações meteorológicas da região. Os pesquisadores aplicaram técnicas de aprendizado de máquina para derivar regras de decisão baseadas nas condições climáticas e volumes de tráfego. Os resultados indicam que a precipitação apresentou impacto mais significativo no volume de tráfego entre 13 e 22 h e que a precipitação, aliada a temperaturas mínima extrema no inverno, causaram uma redução no volume de tráfego.

No que se refere à relação entre a chuva e o período em que ocorre a viagem, a literatura tem mostrado que a chuva afeta o comportamento dos condutores de maneira distinta durante o dia e à noite. O estudo realizado em Pontian, na Malásia, revelou que a chuva noturna acarreta uma redução na velocidade dos veículos, independentemente da intensidade da chuva. Especificamente, os resultados mostraram que, durante chuvas leves, a velocidade média dos veículos reduziu em cerca de 11,4%. Em chuvas moderadas, a redução foi de aproximadamente 25%. Para condições de chuva muito intensa, a redução de velocidade foi menor, cerca de 18,3%, indicando que os motoristas já adotam uma velocidade significativamente reduzida nessas condições (Hassan *et al.*, 2014).

Konstantopoulos *et al.* (2010) investigaram como a experiência de condução e as condições de visibilidade afetam a atenção visual dos motoristas. Esse estudo, conduzido pela “*School of Psychology da University of Nottingham*”, no Reino Unido, usou um simulador de direção para analisar os movimentos oculares de instrutores de direção experientes e motoristas aprendizes enquanto percorriam rotas virtuais durante o dia, à noite e sob chuva. Os resultados mostraram que os instrutores apresentaram uma taxa de movimentação visual mais elevada, ou seja, eles moviam seus olhos com maior frequência para diferentes áreas da via e do painel do

veículo. Ademais, em função da experiência na direção, os instrutores tiveram tempo de processamento mais curtos (tempo que cada motorista usava fixando seus olhos em um ponto antes de mudar para outro) quando comparado aos menos experientes.

Além disso, os autores constataram que em condições de baixa visibilidade, especialmente chuva, houve redução da eficácia da busca visual dos motoristas. Os motoristas tiveram tempo de fixação dos olhos maiores ao dirigir à noite e na chuva em comparação com a rota diurna. Para os motoristas aprendizes, esse resultado não foi surpreendente, pois podem não possuir experiência nessas condições. Todavia, os instrutores também foram afetados pela chuva e não conseguiram manter sua alta taxa de movimentação visual diurna em todas as condições. Ademais, o tempo de processamento das informações pelos instrutores na cena de direção foi maior em condições de visibilidade reduzida, especialmente na condição de chuva (Konstantopoulos *et al.*; 2010).

Agarwal, Maze e Souleyrette (2005) analisaram rodovias em Minnesota (EUA) a partir da avaliação do comportamento de condutores familiarizados com a via em comparação com aqueles que não usam a via frequentemente. Os autores constataram que condutores familiarizados com a via tendem a reduzir menos a velocidade sob chuva, confiando em sua experiência para compensar possíveis riscos.

Jägerbrand e Sjöbergh (2016) analisaram os efeitos das condições meteorológicas, luminosidade natural e iluminação pública influenciam a velocidade dos veículos. A pesquisa, realizada na Suécia, ocorreu de setembro de 2012 a maio de 2014, durante o qual foram coletados dados de cerca de 60 milhões de passagens de veículos em 25 locais distintos, dos quais 17 possuíam iluminação pública e oito não. Os resultados indicaram que a velocidade dos veículos variou de acordo com as condições climáticas, sendo observadas reduções significativas em dias de chuva ou neve. Além disso, constatou-se que a redução da velocidade foi mais acentuada em vias sem iluminação pública, sugerindo que a iluminação artificial pode auxiliar os motoristas na percepção das condições da via, reduzindo o impacto das condições meteorológicas adversas na condução.

No que tange às condições de iluminação natural, as análises comparativas entre períodos de luz do dia e escuridão não revelaram diferenças estatisticamente significativas na velocidade dos veículos. Esse resultado sugere que os motoristas não ajustam sua velocidade conforme a visibilidade reduzida em condições de pouca luz, o que pode explicar a maior incidência de acidentes durante a noite ou em períodos de baixa luminosidade. Os referidos

pesquisadores ainda constataram que com chuva ou com neve, a velocidade do veículo foi menor em vias sem iluminação do que em estradas com iluminação (Jägerbrand e Sjöbergh, 2016).

A chuva também reduz o coeficiente de fricção da estrada, o que pode aumentar a distância de frenagem e o risco de sinistros devido ao desvio do veículo. Rakha (2009) analisou como a precipitação afeta o comportamento dos motoristas, observando que, sob chuva, há uma tendência dos condutores em aumentar a distância de segurança e reduzir a velocidade, impactando o fluxo de tráfego e a capacidade das vias. Nesse mesmo sentido, Asamer *et al.* (2010) investigaram a influência das condições meteorológicas adversas no comportamento dos motoristas, destacando que a chuva leva os condutores a adotarem medidas mais cautelosas, como o aumento da distância de seguimento e a redução da velocidade, afetando o fluxo de saturação e a capacidade das vias.

Kordani, Rahmani e Nasiri (2018) investigaram o impacto de condições meteorológicas adversas na distância de frenagem em rodovias no Irã. A pesquisa analisou a influência do coeficiente de atrito da via em condições de chuva intensa. Para isso, foram realizados testes com veículos de passeio em pistas secas e molhadas, alterando os tipos de pavimento e a intensidade da precipitação. Os resultados demonstraram que a distância de frenagem aumenta consideravelmente em condições chuvosas, e os motoristas tendem a modificar o comportamento de frenagem e aceleração para compensar a menor aderência da pista. Entretanto, mesmo com esses ajustes, o risco de perda de controle do veículo ainda foi significativo.

Wilson (2013) estudou sobre o acúmulo de contaminantes, incluindo óleo, na superfície das pistas e seu impacto na resistência ao deslizamento dos pavimentos rodoviários. O autor destaca que, durante períodos secos, materiais como poeira e óleo acumulam-se na superfície das vias. Quando ocorre precipitação, esses contaminantes misturam-se com a água, formando uma camada escorregadia que reduz a aderência dos pneus ao pavimento. Este fenômeno contribui para a variação sazonal da resistência ao deslizamento, afetando a segurança viária.

A presença de spray (névoa de água) e partículas de gotas de chuva também pode reduzir a visibilidade da via, afetando a segurança (Wang *et al.*, 2021). Ghasemzadeh e Ahmed (2017) investigaram, com base em dados do SHRP 2 *Naturalistic Driving Study* (NDS) dos Estados Unidos, a habilidade do motorista de manter a faixa de tráfego durante condições de chuva intensa e constataram que os motoristas foram 3,8 vezes mais propensos a mostrar maior desvio

de faixa em comparação com condições sem chuva. Além disso, eles observaram reduções médias de velocidade de 23% em chuva leve e 29% em chuva forte, em comparação com a situação sem chuva.

Os referidos autores também demonstraram que, em média, os condutores reduziram a velocidade de 92,4 km/h (tempo seco) para 87,6 km/h (chuva intensa), uma diferença de 4,8 km/h. No entanto, ao se analisar individualmente o desempenho dos motoristas, verificou-se que alguns reduziram sua velocidade em até 15 km/h, enquanto outros apresentaram variações inferiores a 1 km/h. Essa dispersão evidencia que a adaptação ao risco provocado pela chuva não é uniforme entre os condutores (Ghasemzadeh e Ahmed, 2017).

Outro estudo de D'Apice *et al.* (2010) aplicou uma abordagem dinâmica fluida para otimizar o comportamento do tráfego, ressaltando os mesmos fatores de congestionamento. De maneira similar, um estudo de Onyeneke *et al.* (2018) modelou os efeitos do congestionamento de trânsito nas atividades econômicas e constatou que sinistros, fatalidades e outras ocorrências similares são fatores críticos que acentuam o congestionamento.

Ademais, Pi *et al.* (2019) também contribuíram para a discussão com análises visuais das causas do congestionamento, corroborando que o excesso de veículos em horários específicos e eventos inesperados, como pneus furados e condições climáticas, são determinantes para o congestionamento urbano. O estudo foi realizado na Coreia do Sul, onde há um verão chuvoso devido à monção de verão, seguido por invernos secos e frios.

Stern *et al.* (2003) analisaram o impacto do clima no fluxo de tráfego na região metropolitana de Washington (EUA). Ademais, os autores observaram variações nos impactos conforme os períodos do dia, diferenciando entre horários de pico e fora de pico. Para tal, foram utilizados dados meteorológicos fornecidos por três aeroportos (*Dulles International, Washington National e Baltimore/Washington International*). Os dados referentes aos tempos de viagem foram obtidos junto ao “*SmarTraveller*”, um serviço baseado na web que fornece informações incluindo tempo de viagem, locais de acidentes, zonas de trabalho, entre outros.

Os resultados indicaram que, considerando medições meteorológicas regionais, houve um aumento médio de 12% nos tempos de viagem devido a fatores como chuva, vento e baixa visibilidade. No entanto, ao analisarem dados específicos de segmentos rodoviários, os resultados revelaram variações significativas entre os diferentes trechos analisados. Isso sugere que o impacto do clima sobre o tráfego não é homogêneo e pode depender de fatores como tipo de rodovia, volume de tráfego e infraestrutura disponível para drenagem da pista. Os autores

supracitados constataram também que durante os períodos de entre pico, os tempos de viagem aumentaram cerca de 13% devido às condições climáticas adversas. Esses resultados destacam que, embora as condições meteorológicas afetem o tráfego em todos os períodos, os impactos são mais evidentes durante os horários de pico, possivelmente devido à maior densidade de veículos e à menor flexibilidade para ajustes de velocidade ou de rotas alternativas (Stern *et al.*, 2003).

O estudo de Essien *et al.* (2018), realizado em vias arteriais de Manchester - Inglaterra, ainda mostrou que fora do período de pico, a velocidade média dos veículos foi de 43,65 km/h, 41,50 km/h, 41,26 km/h e 48,63 km/h nas condições de sem chuva, chuva leve, moderada e forte, respectivamente. No período de pico, a velocidade média dos veículos foi de 27,79 km/h, 28,93 km/h, 27,08 km/h e 25,06 km/h nas condições de sem chuva, chuva leve, moderada e pesada, respectivamente. Assim, percebe-se que a chuva interfere no tráfego urbano, todavia, depende da intensidade e dos horários em que ocorrem (pico/fora do pico). Nos períodos de pico, estes autores notaram um aumento de 4,2% na velocidade média dos veículos nos períodos com chuvas leves e redução de 2,6% e 9,7% quando ocorriam chuvas moderadas e fortes, respectivamente. Fora do horário de pico, ocorreu uma redução na velocidade dos veículos na ordem de 4,9% e de 5,5% em períodos de chuvas leves e moderadas e um aumento de 11,4% em situações de chuva pesada. Todavia, ressalta-se que as amostras desta pesquisa para as situações de chuva pesada foram muito pequenas, o que pode ter contribuído com os resultados encontrados.

No que tange ao comportamento do condutor diante de condições climáticas adversas, diversas pesquisas indicam que os condutores tendem a subestimar os riscos associados ao clima (Edwards, 1999 e Kilpeläinen e Summala, 2007). Embora eles adaptem sua condução até certo limite, diminuindo a velocidade, aumentando a distância de segurança e evitando manobras como ultrapassagens (Van Der Hulst *et al.*, 1999), suas ações são mais influenciadas pela percepção subjetiva do risco do que por uma avaliação precisa do perigo real.

O estudo de Kilpeläinen e Summala (2007) teve como objetivo avaliar como motoristas ajustam sua velocidade de condução sob diferentes intensidades de chuva, com ênfase na percepção de risco e nas diferenças entre os perfis de condutores. Utilizando dados de sensores automáticos instalados em veículos, os autores analisaram trajetos realizados em condições de tempo seco, chuva leve e chuva intensa. Os resultados mostraram que a redução de velocidade média dos veículos foi de 1,3 km/h sob chuva leve e de 3,3 km/h sob chuva intensa, em comparação com as condições de tempo seco. A análise também revelou que a magnitude da

redução variava consideravelmente entre os motoristas. Aqueles que normalmente dirigem em velocidades mais altas apresentaram reduções de velocidade mais pronunciadas durante a chuva, enquanto os condutores mais cautelosos mostraram pouca ou nenhuma alteração no comportamento de velocidade.

Essa diferença de resposta foi interpretada por Kilpeläinen e Summala (2007) com base na teoria da motivação do risco, segundo a qual os motoristas mantêm um “nível-alvo” de risco aceitável. Assim, os condutores mais agressivos (com tendência a velocidades maiores) percebem um risco adicional mais significativo em condições adversas, levando-os a reduzir a velocidade de forma mais acentuada. Já motoristas mais conservadores, por dirigirem em velocidades naturalmente mais baixas, não percebem necessidade de ajustes em sua condução.

Yeo *et al.* (2020) realizaram um estudo para investigar os efeitos da chuva sobre o comportamento de condução, a partir da análise da volatilidade veicular, definida como a variação momentânea e imprevisível de aceleração e frenagem durante a condução. O estudo utilizou dados de GPS de 620 táxis na cidade de Seul (Coreia do Sul), com registros de velocidade, aceleração e localização geográfica em tempo real. Os dados foram integrados a informações meteorológicas locais para associar eventos de condução a condições de precipitação. Os resultados mostraram que, mesmo com velocidades médias mais baixas durante a chuva, os motoristas apresentaram aumento na frequência de acelerações e desacelerações abruptas, indicando um comportamento mais reativo e instável.

Guo e Fang (2013) propuseram um modelo de avaliação individual de risco com base em dados do *100-Car Naturalistic Driving Study*, que monitorou 98 motoristas ao longo de mais de 2 milhões de milhas e 43.000 horas de condução. Utilizando um modelo hierárquico bayesiano, os autores estimaram a taxa de eventos críticos por milha percorrida, identificando três perfis distintos de risco: baixo (0,39 eventos/milha), moderado (1,75) e alto risco (3,95). Os condutores classificados como de alto risco apresentaram maior frequência de acelerações e frenagens bruscas, maiores desvios laterais da faixa e maior envolvimento em situações de ultrapassagem imprudente. Esses comportamentos foram interpretados como indícios de um estilo de condução mais agressivo e menos defensivo. Porém, os motoristas de baixo risco tendiam a manter velocidades mais estáveis, realizar menos manobras abruptas e demonstrar maior atenção às condições do tráfego.

Essa variabilidade individual implica que estratégias genéricas de segurança viária, como campanhas amplas ou limites de velocidade padronizados, podem ser insuficientes para

alcançar os condutores de maior risco. Diante disso, os Guo e Fang (2013) defendem a adoção de abordagens personalizadas, que considerem os dados reais de comportamento de cada motorista. Isso pode incluir, por exemplo, programas de reeducação voltados a perfis específicos, políticas públicas que priorizem intervenções direcionadas a grupos mais vulneráveis, e modelos de seguro baseados no desempenho individual (conhecidos como *usage-based insurance*), nos quais condutores com histórico de condução mais segura pagariam valores reduzidos pelas apólices de seguro, enquanto motoristas com maior risco assumiriam custos proporcionais ao seu perfil comportamental. Essa personalização permite otimizar recursos e maximizar a efetividade das ações, promovendo um ambiente viário mais seguro e adaptado às características reais da população condutora.

Os autores justificaram os resultados a partir da premissa de que o risco no trânsito não está uniformemente distribuído entre os condutores, sendo fortemente influenciado por características individuais, como impulsividade, atenção, experiência e estilo de condução. O modelo proposto permite, portanto, uma avaliação mais precisa do risco associado a cada motorista, oferecendo uma base potencial para intervenções direcionadas, políticas de reeducação, e programas de seguro baseados em comportamento.

A Teoria da Homeostase de Risco (THR) também pode ser utilizada para justificar o comportamento do condutor diante de situações consideradas adversas. Essa teoria propõe que os indivíduos mantêm um nível subjetivo de risco considerado aceitável, ajustando seu comportamento de modo a não ultrapassar esse limiar pessoal. Aplicada ao contexto da condução, a teoria sugere que os motoristas modulam suas decisões e ações, como velocidade, uso de dispositivos ou intensidade de frenagens, conforme a percepção que têm do risco envolvido em determinada situação (Kita *et al.*, 2022).

Ou seja, quando o risco percebido aumenta (por exemplo, devido a uma chuva intensa ou à presença de radares), o condutor tende a adotar comportamentos mais cautelosos, como reduzir a velocidade ou aumentar a distância de segurança. Por outro lado, se o risco percebido for baixo, ele pode se sentir confortável para assumir comportamentos mais arriscados, como utilizar o celular ao volante ou ultrapassar o limite de velocidade.

No experimento conduzido por Kita *et al.* (2022), observou-se que a introdução de um alerta visual durante o uso do smartphone aumentou a percepção de risco no grupo experimental. Como consequência, os motoristas reduziram o uso do celular, validando a

premissa de que o comportamento é ajustado de forma a manter o risco dentro de um patamar considerado aceitável pelo indivíduo.

Essa teoria ajuda a explicar por que, mesmo diante de campanhas educativas ou normas legais, certos motoristas continuam adotando condutas de risco, pois sua percepção do perigo envolvido pode não ter sido alterada de forma efetiva. Portanto, segundo a THR, ações que aumentem a percepção real de risco e não apenas as punições tendem a ser mais eficazes na promoção de comportamentos seguros no trânsito.

Nesse sentido, Edwards (1999) discute como a percepção de risco influencia o comportamento dos motoristas e propõe que as decisões tomadas ao volante são mediadas por mecanismos individuais de autorregulação. Com base na Teoria da Homeostase de Risco, o autor argumenta que os condutores tendem a manter um nível subjetivo de risco constante. Assim, melhorias nas condições de segurança veicular ou viária (como o uso de cintos de segurança, airbags ou freios ABS) podem ser compensadas por comportamentos mais arriscados, especialmente o aumento da velocidade. O autor observa que motoristas com baixa percepção de risco são mais propensos a conduzir em velocidades elevadas, o que representa um ajuste comportamental para manter seu nível habitual de risco. Embora o estudo não trate sobre aceleração ou frenagem, ele destaca a velocidade como uma variável que interfere na regulação do comportamento de risco ao volante. Além disso, Edwards aponta que fatores como confiança excessiva nas próprias habilidades, experiência de condução e atitudes em relação às regras de trânsito também modulam essa percepção de risco e influenciam nas decisões de direção. Esses resultados ajudam a compreender por que alguns motoristas não adaptam sua velocidade mesmo sob condições adversas, como chuva ou baixa visibilidade.

2.4.3.2 Métodos de Coleta de Dados sobre Comportamento do Condutor

O estado da arte da pesquisa sobre métodos utilizados para coletar dados sobre o comportamento de motoristas no trânsito indicou a existência de quatro procedimentos. O primeiro deles consiste na obtenção de informações por meio da aplicação de questionários entre motoristas. Todavia, como os dados coletados são informados pelos condutores, a validade das informações é contestada por pesquisadores, pois podem não refletir o comportamento real (AGRAMUNT, 2018; BLANCHARD *et al.*, 2010). Em contraste, é possível investigar o comportamento de motoristas a partir da análise dos registros de sinistros,

a fim de coletar dados sobre os motoristas que permitem a reconstrução dos eventos. Todavia, Schagen van e Sagberg (2012) apontam que esse procedimento não fornece uma compreensão completa do comportamento do motorista.

Choudhary e Velaga (2017), Pawar *et al.* (2020) e Singh e Kathuria (2021) estudaram sobre o uso da técnica de simuladores de direção, no qual os dados sobre o comportamento do condutor são coletados em um ambiente altamente controlado, utilizando simuladores avançados de veículos. Todavia, os motoristas se comportam de forma diferente em um ambiente simulado quando comparado à direção natural (ZÖLLER *et al.*, 2019).

Por fim, a literatura tem revelado a potencialidade de estudos naturalísticos, nos quais são coletadas informações sobre o desempenho do veículo e do motorista no seu cotidiano, considerando as eventualidades do trânsito (congestionamentos, sinalizações viárias) e do ambiente (condições climáticas e de luminosidade). De acordo com Singh e Kathuria (2021), a compreensão do comportamento do motorista auxilia na implementação de medidas de segurança pré-colisão, bem como no desenvolvimento de políticas de fiscalização, em projetos de infraestrutura e sistemas inteligentes de segurança veicular.

2.5 Considerações Finais

A influência da precipitação no comportamento dos motoristas revela impactos na velocidade, visibilidade, tempo de reação, aceleração, frenagem e segurança viária. As condições de chuva, especialmente intensas e noturnas, levam a reduções na velocidade dos veículos e aumentam a cautela ao dirigir. Além disso, a combinação de escuridão e chuva reduz ainda mais a visibilidade e a segurança.

Essas condições adversas aumentam a distância de frenagem e o risco de sinistros devido ao menor coeficiente de fricção e à presença de spray. Os motoristas ajustam seu comportamento em resposta à chuva, afetando o tráfego e aumentando o congestionamento durante os horários de pico.

A revisão da literatura sobre métodos de coleta de dados sobre o comportamento dos motoristas destaca a importância dos estudos naturalísticos para entender o comportamento real dos condutores em diversas condições. Como os esses estudos fornecem uma base robusta para o desenvolvimento de medidas de segurança pré-colisão, políticas de fiscalização e melhorias na infraestrutura viária, o capítulo a seguir discute sobre os Estudos Naturalísticos de Direção (NDS) e sua relevância para entender o comportamento dos condutores em situações reais de

tráfego. O uso desse método pode contribuir para a criação de um ambiente de condução mais seguro e eficiente, especialmente em condições de chuva.

3. ESTUDO NATURALÍSTICO DE DIREÇÃO

3.1 Considerações iniciais

Este capítulo aborda sobre os Estudos Naturalísticos de Direção (*Naturalistic Driving Studies - NDS*) e sua relevância para compreender o comportamento dos condutores em situações reais de tráfego. Além disso, são apresentados conceitos e metodologias dos NDS. Este capítulo também discorre sobre as limitações desses estudos e apresenta exemplos de sua aplicação em diversos países, incluindo Brasil, Estados Unidos, Europa e Japão.

3.2 Caracterização dos estudos naturalísticos de direção

Os estudos naturalísticos de direção (NDS) permitem entender o comportamento dos condutores em situações reais de tráfego. Van Nes *et al.* (2019) definem esses estudos como métodos que fornecem informações sobre o comportamento dos motoristas durante suas viagens cotidianas. Esses dados são coletados por meio de equipamentos não invasivos e sem intervenção experimental, proporcionando uma visão autêntica das práticas de condução.

Os estudos naturalísticos de direção destacam-se por permitir a observação detalhada e contextualizada do comportamento dos motoristas em situações reais, algo que os métodos tradicionais de pesquisa não conseguem capturar com a mesma precisão. Essa abordagem fornece uma base sólida para o desenvolvimento de intervenções de segurança e políticas de transporte mais eficazes, direcionadas por evidências reais do comportamento dos motoristas.

3.3 Aplicação de estudos naturalísticos no comportamento dos condutores de veículos

Diversos países têm conduzido estudos naturalísticos para entender o comportamento dos motoristas e melhorar a segurança no trânsito. Entre os estudos mais notáveis estão:

3.3.1 Estados Unidos

Estudo desenvolvido pelo *Virginia Tech Transportation Institute (VTTI)* analisou o comportamento de 241 motoristas em 100 veículos ao longo de mais de um ano, registrando 42.300 horas de condução. Para tal, foram utilizados sensores e câmeras que coletavam dados sobre velocidade, frenagem, aceleração e reações dos condutores em tempo real. Os resultados indicaram que 78% dos quase-acidentes e 65% dos sinistros estavam relacionados à distração do motorista, sendo o uso de celulares um dos principais fatores de risco. (Neale *et al.*, 2005)

Além disso, esse estudo constatou que motoristas que dirigiam em alta velocidade ou com curta distância de seguimento apresentaram menor tempo de reação e maior risco de colisões traseiras. A pesquisa revelou ainda que muitos condutores não ajustavam sua velocidade de maneira adequada a condições climáticas adversas, elevando o risco de acidentes. (Neale *et al.*, 2005)

O SHRP 2 Naturalistic Driving Study (NDS - Estudo Naturalista de Direção SHRP 2), conduzido entre os anos de 2010 e 2013, coletou dados sobre o comportamento dos motoristas em condições reais, por meio de sensores, câmeras e instrumentos instalados em mais de 3.500 motoristas e 5.000 veículos durante vários anos. O objetivo desta pesquisa foi compreender as causas dos acidentes, analisando fatores como distrações, reações a eventos inesperados e interações com o ambiente viário. Os dados coletados em tempo real incluíam informações sobre a velocidade, uso de freios, aceleração e até o movimento dos olhos dos motoristas, proporcionando a criação de uma base de dados robusta para análises detalhadas de aspectos que influenciam na segurança viária (Campbell, 2012).

Os resultados desta pesquisa mostraram que aproximadamente 68% dos acidentes e quase-acidentes estavam relacionados a algum tipo de distração nos segundos anteriores ao evento, sendo o uso de celulares um dos principais fatores de risco. Além disso, a fadiga ao volante foi identificada como um problema significativo, aumentando em até 21% a probabilidade de acidentes (Dingus *et al.*, 2016).

Richard *et al.* (2020) utilizaram dados de direção naturalística SHRP 2 para examinar o comportamento de excesso de velocidade do motorista e identificar a frequência de episódios de excesso de velocidade. Foram analisadas 100 viagens de 2.910 motoristas com idades entre 16 e 64 anos. Os dados foram segmentados em episódios de excesso de velocidade (EEV) e episódios de fluxo livre, representando oportunidades de acelerar acima do limite regulamentado. Os resultados mostraram que dirigir 10 mph acima do limite de velocidade era comum, com 99,8% dos motoristas apresentando pelo menos um episódio de excesso de velocidade durante suas viagens, resultando em uma média de 2,75 EEV por viagem e um total de 623.202 EEV registrados. O estudo investigou episódios mais extremos, onde a velocidade excedia o limite em pelo menos 15 mph, totalizando 71.113 EEV. A maioria desses episódios teve velocidades máximas entre 12 mph e 15 mph acima do limite e durou menos de dois minutos.

Os dados indicaram que a maioria dos motoristas passou menos de 5% do tempo de fluxo livre em excesso de velocidade, enquanto poucos motoristas ultrapassaram 10% do tempo. Além disso, condutores mais jovens apresentaram uma maior proporção de tempo excedendo os limites de velocidade em comparação com os mais velhos (Richard *et al.*, 2020).

Seacrist *et al.* (2021), a partir dos dados do SHRP 2 *Naturalistic Driving Study* (NDS) coletados entre 2010 e 2013, analisaram o comportamento de motoristas com o propósito de identificar fatores associados à ocorrência de sinistros. A investigação concentrou-se na influência das condições ambientais adversas e dos comportamentos de risco, bem como no potencial dos Sistemas Avançados de Assistência ao Motorista (ADAS) para mitigar esses fatores. O estudo avaliou a capacidade dessas tecnologias em reduzir a frequência e a gravidade dos sinistros viários.

Os resultados indicaram que 94% dos acidentes analisados tinham o erro humano como fator crítico, sendo que erros de percepção e reconhecimento, como distração interna e vigilância inadequada, representaram a maior parte desses erros. Adicionalmente, o estudo observou que os motoristas mais jovens apresentaram maior tendência a cometer erros de decisão, enquanto os motoristas idosos foram mais propensos a erros relacionados ao desempenho (Seacrist *et al.*, 2021).

3.3.2 Europa

UDRIVE (*European naturalistic Driving and Riding for Infrastructure & Vehicle Safety and Environment*) foi o primeiro estudo em larga escala de condução naturalística realizado em sete países europeus. O projeto, iniciado em outubro de 2012 e concluído em junho de 2017, acompanhou o comportamento de motoristas de automóveis, caminhões e motociclistas, em condições reais de tráfego. O UDRIVE coletou dados de mais de 200 veículos ao longo de 21 meses, totalizando 4 milhões de quilômetros e 87.870 horas de dado. O objetivo foi entender o comportamento dos condutores e as interações com o ambiente viário, visando melhorar a segurança viária e a eficiência ambiental (Van Nes *et al.*, 2019).

Os resultados dessa pesquisa indicaram que motoristas de carro estavam envolvidos em atividades de distração por aproximadamente 10% do seu tempo de direção, em comparação com 0–4% nos outros países como França, Alemanha, Reino Unido, Holanda e Espanha. A atividade de distração mais comum foi o uso de celular na mão, ocorrendo em média aproximadamente 4% do tempo de direção. Na Polônia, o tempo de uso

<https://www.sciencedirect.com/topics/psychology/mobile-phone> de celular foi superior ao do Reino Unido, França ou Alemanha (Carsten *et al.*, 2017). Esse autor também menciona que os dados do UDRIVE mostraram que, os motoristas de caminhão envolvem mais em tarefas secundárias do que para motoristas de carro - aproximadamente 20% do tempo de direção. Os motoristas de caminhão passavam a maior parte desse tempo comendo/bebendo e usando o telefone (5% cada). Além disso, quase metade do tempo usando o telefone compreendia mensagens de texto, leitura ou outras interações visuais.

As análises iniciais dos dados do UDRIVE mostram que as diferenças entre os países podem ser significativas. Os resultados encontrados em um país não se aplicam necessariamente a outro, demonstrando a necessidade de estudos regionais direcionados (Carsten *et al.*, 2017).

Dotzauer *et al.* (2017), a partir dos dados do UDRIVE, estudaram sobre direção arriscada e relataram que em aproximadamente 87% das viagens de carro, os motoristas estavam com os cintos de segurança afivelados do início ao fim da viagem. Essa porcentagem diferiu de um país para outro, com a menor na Polônia (76%) e a maior na Holanda (96%). Os homens tiveram uma taxa significativamente maior de cintos de segurança desafivelados do que as mulheres. Ademais, os cintos de segurança foram deixados desafivelados com mais frequência durante viagens que ocorreram a noite, em comparação com viagens diurnas, embora apenas para viagens de menos de 325 m.

Dotzauer *et al.* (2017) também constatou que os motoristas se adaptavam ao ambiente e à situação do trânsito ao ultrapassar outros carros ou caminhões. Os condutores estavam menos inclinados a ultrapassar em condições climáticas adversas ou quando havia tráfego na faixa contrária. Notavelmente, em aproximadamente 12% das manobras de ultrapassagem, os motoristas violaram restrições legais.

Além do exposto, as análises dos dados do UDRIVE mostraram que as diferenças entre os países podem ser significativas. Os resultados encontrados em um país não se aplicam necessariamente a outro, demonstrando a necessidade de estudos regionais direcionados (VAN NES *et al.*, 2019).

Pantangi *et al.*, (2020) analisou o impacto dos programas de fiscalização de alta visibilidade no comportamento agressivo de direção. Utilizando dados de estudos de condução naturalística, o estudo avaliou mudanças no comportamento dos motoristas antes e depois da

implementação desses programas. O objetivo foi determinar a eficácia da fiscalização de alta visibilidade em reduzir comportamentos agressivos e melhorar a segurança no trânsito.

Faria *et al.* (2020) avaliaram o impacto do ambiente de direção no comportamento dos motoristas em diferentes condições viárias e meteorológicas da Região Metropolitana de Lisboa - Portugal. A pesquisa monitorou 47 motoristas ao longo de seis meses, entre os anos de 2013 e 2015, utilizando dispositivos de monitoramento a bordo instalados nos veículos, coletando dados de 33.000 viagens, cobrindo aproximadamente 307.800 km e 8.028 horas de condução.

Os resultados indicaram que, durante chuvas intensas, houve uma redução de 22% na velocidade média em comparação com condições secas, além de uma diminuição de 8% nas acelerações e 11% nas frenagens. No entanto, a frequência de frenagens e acelerações bruscas não apresentou alterações significativas entre motoristas mais experientes em condução sob chuva, sugerindo que a habituação às condições chuvosas pode reduzir a percepção de risco e minimizar ajustes no comportamento de direção.

3.3.3 Japão

Suto *et al.* (2007) analisaram o comportamento de motoristas em trechos viários identificados como de alto risco e a influência de informações de alerta em interseções na redução dos sinistros. Os resultados deste estudo mostraram que a presença de sinais de alerta dinâmicos em interseções reduziu a velocidade dos motoristas em até 12% nos trechos analisados, sugerindo uma maior percepção de risco induzida pela sinalização.

Yoh *et al.*, (2017) compara as características dos motoristas estrangeiros no Japão, analisando dados de violações de trânsito e sinistros. O estudo analisou estatísticas de infrações e sinistros envolvendo motoristas estrangeiros, comparando-os com motoristas locais. O objetivo foi identificar diferenças de comportamento e propor medidas para melhorar a segurança viária para motoristas estrangeiros. Os resultados mostraram que o senso de prioridade, velocidade e compreensão das regras afetam as infrações de trânsito. Motoristas asiáticos tendem a violar as regras relacionadas à prioridade em rodovias, enquanto norte-americanos e sul-americanos violam regras relacionadas à velocidade, e motoristas do sudeste asiático violam regras relacionadas à prioridade e placas de sinalização.

Estudos como os de Richard *et al.* (2020) e Borguezani *et al.* (2020) utilizam metodologias naturalísticas para capturar dados detalhados sobre o comportamento dos condutores em condições reais de tráfego, especialmente em relação à escolha da velocidade.

Essas abordagens têm se mostrado relevantes, pois permitem a coleta de dados do ambiente em que os motoristas circulam, sem interferências artificiais, proporcionando uma visão mais precisa das variáveis que influenciam o comportamento ao volante. Ao contrário de experimentos controlados, as metodologias naturalísticas revelam o comportamento em situações reais, permitindo uma análise mais aprofundada e aplicável às intervenções viárias (Richard *et al.*, 2020; Borguezani *et al.*, 2020; Santos *et al.*, 2021).

3.3.4 Brasil

No contexto brasileiro, os estudos naturalísticos ainda são incipientes, mas apresentam potencial para influenciar a segurança viária. O Brasil possui elevadas taxas de sinistros e mortalidade no trânsito, o que evidencia a necessidade de pesquisas que avaliam o comportamento dos motoristas em condições reais de condução. Nesse sentido, o Estudo Naturalístico de Direção Brasileiro (NDS-BR) surge como uma das primeiras iniciativas desenvolvidas no país com o objetivo de compreender o comportamento dos condutores e fornecer elementos que subsidiem políticas públicas e melhoria na segurança (Amâncio, 2021; Silva *et al.*, 2020).

A Plataforma de Coleta de Dados Naturalísticos (PCDN) do NDS-BR utiliza um sistema não intrusivo, composto por um computador portátil capaz de processar dados de câmeras, além de câmeras de alta definição para capturar as imagens internas e externas dos veículos, e um módulo GPS para registrar as coordenadas e a velocidade dos veículos. A frequência de coleta foi de 1 segundo, garantindo precisão nos dados. Essa tecnologia permitiu a coleta contínua sem interferir no comportamento dos motoristas, preservando a autenticidade dos dados coletados (Richard *et al.*, 2020; Borguezani *et al.*, 2020; Gadda *et al.*, 2021).

Com os dados coletados pelo NDS-BR, Gonzalez *et al.* (2022) analisaram a influência do uso do celular ao volante em motoristas de Curitiba, identificando que a distração causada pelo manuseio do dispositivo estava associada a tempos de reação mais lentos e a um aumento significativo no risco de colisões traseiras.

Além desse estudo, Gadda *et al.* (2021) avaliaram a influência de radares e lombadas eletrônicas na redução da velocidade dos motoristas e constatou que a presença desses dispositivos gerou redução média na velocidade operacional de 22% nos trechos monitorados.

Os dados do NDS-BR também foram utilizados para avaliar a segurança dos pedestres. Nesse sentido, Borguezani *et al.* (2020) estudaram a interação entre motoristas e pedestres em

faixas de travessia não semaforizadas e concluíram que menos de 50% dos condutores reduziam a velocidade ou davam preferência aos pedestres em locais nos quais a travessia era permitida pela legislação. Além disso, esse estudo constatou que a distância do pedestre em relação à faixa tem influência na probabilidade de o motorista ceder a passagem para o transeunte.

A importância desse estudo está na sua capacidade de gerar dados relevantes sobre o comportamento dos motoristas, facilitando o desenvolvimento de intervenções baseadas em evidências, como políticas públicas e melhorias de infraestrutura viária. Pesquisas futuras que expandam o NDS-BR para outras regiões do Brasil serão fundamentais para aumentar a representatividade dos dados e fornecer um panorama mais abrangente do comportamento de direção no país (Amâncio, 2021; Gonzalez *et al.*, 2022).

3.4 Limitações dos estudos naturalísticos

Uma das principais limitações dos estudos naturalísticos é a quantidade de recursos necessários para o levantamento, processamento, tratamento e análise de dados, especialmente no que tange a hardware, software e recursos humanos para assistir e tabular as informações coletas nos vídeos segundo a segundo. A instrumentalização dos veículos possui um custo elevado e é complexa, o que tende a limitar o tamanho da amostra e levantar questionamentos sobre a validade da generalização dos dados obtidos. Essas limitações podem ser ainda estendidas por problemas na qualidade dos dados ou pelo período de adaptação dos pesquisadores a aprenderem a utilizar e interpretar múltiplos dados complexos (Ehsani *et al.*, 2021).

3.5 Considerações Finais

As considerações dos Estudos Naturalísticos de Direção (NDS) ressaltam sua importância no cenário global para a compreensão do comportamento dos motoristas em condições reais de tráfego. Através da coleta de dados, sem interferência experimental, esses estudos permitem uma análise precisa de variáveis como, velocidades, acelerações, frenagens e interações com o ambiente viário. No Brasil, o Estudo Naturalístico de Direção Brasileiro (NDS-BR) representa um marco na pesquisa de segurança viária, trazendo dados para o desenvolvimento de intervenções e políticas públicas voltadas para a redução de acidentes e melhoria da segurança no trânsito.

Apesar de sua eficácia em fornecer dados ricos e contextualizados, os estudos naturalísticos possuem custo elevado de instrumentalização dos veículos e alta complexidade

no tratamento de volumes de dados. Além disso, a necessidade de expandir as amostras e incluir mais regiões geográficas permite a garantia da representatividade e da generalização dos resultados.

4. O PROCESSO DE REAMOSTRAGEM


De acordo com HABERMEHL (2018), amostras de tamanho insuficiente podem resultar em conclusões influenciadas pelo acaso, comprometendo a validade das inferências estatísticas. Nesse sentido, métodos de reamostragem como o *bootstrap*, e o Modelo de Aprendizagem de Máquina são aplicados com o intuito de ampliar a base de dados, minimizar distorções e aumentar a precisão das estimativas estatísticas (Moore; McCabe; Duckworth; Sclove, 1996).

O *bootstrap* é uma técnica que permite a geração de reamostras a partir dos dados coletados no ambiente real, preservando suas características sem considerar suposições sobre distribuições teóricas (Carmo e Lima, 2017). Por outro lado, o Aprendizado de Máquina, embora seja eficaz na criação de dados sintéticos e na identificação de padrões, pode resultar na generalização dos dados e na perda de variações naturais do comportamento analisado (Leão *et al.*, 2021).

Diante do exposto, recomenda-se a utilização do *bootstrap*, uma vez que esse método de reamostragem não apenas garante estimativas mais representativas da variabilidade observada no ambiente real, mas também possibilita a estimativa de propriedades de grandes amostras a partir de um conjunto limitado de observações (Alves, 2013). Essa abordagem é vantajosa por manter a fidelidade às características originais dos dados, evitando distorções que podem surgir com outras técnicas.

O método *bootstrap*, desenvolvido por Efron e Tibshirani em 1979, pode ser usado para amostras que possuem distribuições conhecidas e quando não se tem nenhuma suposição sobre ela (Alves, 2013). Tal procedimento estatístico computacional utiliza a reamostragem, ou seja, gera várias novas amostras, todas com o mesmo tamanho da amostra original, selecionando aleatoriamente seus elementos, conforme Figura 4.1. Como a seleção ocorre com reposição, algumas observações podem se repetir enquanto outras podem não ser escolhidas. Esse procedimento é replicado diversas vezes, permitindo a obtenção de estimativas estatísticas mais precisas, como médias, medianas e intervalos de confiança, sem a necessidade de coletar novos dados (Maddala, 2003; Chernick e Labudde, 2010; Alves, 2013).

Figura 4.1 mostra o procedimento de reamostragem pelo referido método.



Fonte: Adaptado de Alves (2013)

Assim, com base em uma amostra original de tamanho n , $x = (x_1, x_2, \dots, x_n)$, gera-se amostras *bootstrap*, $x^* = (x_1^*, x_2^*, \dots, x_n^*)$, aleatoriamente e com reposição a partir de $x = (x_1, x_2, \dots, x_n)$ (ALVES, 2013). Para a obtenção de resultados confiáveis, é necessário realizar uma série amostras *bootstrap* com o mesmo tamanho n . Segundo Efron e Tibshirani (1983), a distribuição *bootstrap* aproxima-se da distribuição real à medida que o número de amostras *bootstrap* tende ao infinito. Para Montgomery e Runger (2003), o número de amostras *bootstrap* pode ser determinado, analisando a variação do desvio padrão da estimativa do parâmetro investigado, conforme novas amostras *bootstrap* são geradas. A estabilização desse valor, a partir do aumento das referidas amostras, indica que a quantidade de amostras *bootstrap* é suficiente para a análise.

Em seguida, para cada uma das amostras *bootstrap*, $x^* = (x_1^*, x_2^*, \dots, x_n^*)$, estima-se o parâmetro de interesse, $\hat{\theta}$, por meio de réplicas *bootstrap* $\hat{\theta}_b^* = s(x_b^*)$, onde $b = 1, 2, \dots, B$ e se refere ao número de repetições (amostras *bootstrap*). Essas réplicas formam uma distribuição empírica, que permite analisar a variabilidade do parâmetro estudado e realizar inferências estatísticas (Chernick e Labudde, 2010).

Conforme exposto por Moore, McCabe, Duckworth e Sclove (2006), pode-se considerar que o método *bootstrap* aparenta gerar dados artificialmente, o que pode suscitar desconfiança. No entanto, esse procedimento não implica a criação de novos dados, mas sim a utilização das informações das reamostras como representações dos dados originais. Salienta-se que o uso do *bootstrap* não substitui a necessidade de adição de novos dados na amostra com objetivo de aumentar a precisão. Ao contrário, sua aplicação está fundamentada no uso das médias das reamostras para estimar a variabilidade da média amostral de uma amostra de tamanho N , extraída da população, como consequência da amostragem aleatória.

A partir da estimativa de uma variável obtida por meio de uma amostra de dados, dois dos objetivos do método *bootstrap* são: estimar o erro padrão associado a essa estimativa e determinar o intervalo de confiança adequado para o parâmetro em questão.

4.1 Erro padrão do Método *bootstrap*

A estimativa do erro padrão *bootstrap* é dada pelo desvio padrão de suas réplicas (Alves, 2013), podendo ser calculada por meio da seguinte equação:

$$\widehat{dp}_{boot}(\hat{\theta}^*) = \sqrt{\left\{ \frac{1}{B-1} \sum_{b=1}^B [s(x_b^*) - s(\cdot)]^2 \right\}},$$

Onde:

$s(x_b^*)$ = valor da estatística para cada amostra *bootstrap*;

B = número de amostras *bootstrap* geradas, e

$$s(\cdot) = \frac{1}{B} \sum_{b=1}^B s(x_b^*)$$

A estimativa do erro padrão pelo método *bootstrap* indica o grau de variação ou dispersão em torno da média (ou valor esperado) (ALVES, 2013)

4.2 Intervalos de confiança baseados no método *bootstrap*

Alves (2013) menciona que há uma variedade de métodos disponíveis para sua estimativa por meio da técnica *bootstrap*. Entre os principais, destacam-se: o intervalo de confiança *bootstrap* padrão, o intervalo de confiança *bootstrap*-t, o intervalo de confiança *bootstrap* percentil, o intervalo de confiança percentil corrigido em relação ao viés (BCPB) e o intervalo de confiança de correção do viés acelerado (Bias-Corrected Accelerated - BCa). A Tabela 4.1 descreve os principais métodos disponíveis para calcular intervalos de confiança utilizando o *bootstrap*, destacando suas vantagens, desvantagens e aplicações. Estas informações permitem comparar as diferentes técnicas, auxiliando na escolha do método mais adequado, conforme o contexto e os objetivos da análise.

Tabela 4.1. Métodos para avaliar o intervalo de confiança no *bootstrap*

Método	Descrição	Vantagens	Desvantagens	Aplicação
<i>bootstrap</i> Padrão	Reamostragem com reposição dos dados para estimar a	Simples de aplicar e não	Pode gerar intervalos de confiança imprecisos se a	Estatísticas como média, variância e regressão.

	distribuição do estimador.	exige suposições fortes.	amostra for pequena ou pouco representativa.	
<i>bootstrap-t</i>	Usa estatística-t e reamostragem para intervalos de confiança.	Melhora a precisão dos intervalos ao considerar a variabilidade do estimador.	Requer mais cálculos e pode não ser adequado para estatísticas muito assimétricas.	Quando se deseja melhorar a precisão da incerteza para estatísticas baseadas em médias.
<i>bootstrap Percentil</i>	Usa quantis da distribuição empírica para construir intervalos.	Fácil de calcular e não depende de distribuições normais.	Pode ser impreciso se os dados forem muito assimétricos.	Aplicado quando a estatística de interesse não tem distribuição normal.
Percentil Corrigido (BCPB)	Ajusta os intervalos para corrigir distorções e vieses.	Intervalos mais precisos, corrigindo assimetrias.	Cálculos mais complexos e requer mais amostras.	Quando há suspeita de vies nos intervalos de confiança.
BCa (Bias-Corrected Accelerated)	Considera assimetria e curvatura da estatística para intervalos mais precisos.	Melhor cobertura de intervalos, ideal para dados não normais.	Computacionalmente mais exigente.	Preferido para estatísticas assimétricas ou quando os dados não seguem distribuição normal.

Fonte: Kvam *et al.* (2022). (Adaptado)

4.3 Aplicação do *bootstrap* na área de Transportes

O estudo conduzido por Sharafeldin *et al.* (2022) foi realizado no estado de Wyoming, Estados Unidos, com o objetivo de investigar os fatores que influenciam a gravidade dos acidentes em interseções, com ênfase no efeito da fricção no pavimento. Para isso, foram analisados nove anos de dados de acidentes em interseções, abrangendo o período de 2007 a 2017 (com exceção dos anos 2010 e 2011), totalizando 402 registros de acidentes em 52 interseções.

Nesse estudo, para garantir robustez estatística nas inferências, foi empregada a técnica de *bootstrap*, por meio da geração de 500 amostras reamostradas com reposição do conjunto original de 402 acidentes. A reamostragem possibilitou obter estimativas mais estáveis dos efeitos de variáveis como fricção do pavimento, uso de cintos de segurança, tipo de interseção (sinalizada ou não), direção imprudente, tipo de acidente, presença de condições adversas, velocidades e frenagens bruscas na gravidade dos acidentes. Essa técnica permitiu reduzir o impacto de possíveis distorções amostrais causadas pelo tamanho relativamente pequeno da amostra original.

Após a aplicação do *bootstrap*, foi possível confirmar que o aumento na fricção do pavimento reduziu a probabilidade de acidentes severos. Além disso, os resultados indicaram

que a presença de interseções sem sinalização e o não uso de cintos de segurança aumentaram a probabilidade de acidentes graves.

Yang e Cooke (2018) avaliaram a precisão das medições de confiabilidade do tempo de viagem e analisaram os efeitos da aplicação do *bootstrap* na melhoria das estimativas de variabilidade nos tempos de deslocamento. Esses autores utilizaram o *bootstrap* para estimar os intervalos de confiança, permitindo identificar o nível de incerteza associado às previsões de tempo de viagem.

O estudo de Yang e Cooke (2018) demonstrou que, antes da aplicação do *bootstrap*, os resultados apresentavam maior dispersão e incerteza, dificultando a confiabilidade das previsões. Após a aplicação da referida técnica, os intervalos de confiança se tornaram mais estáveis, reduzindo a incerteza associada às medições de tempo de viagem. Os intervalos de confiança no percentil 95 foram mais amplos antes da reamostragem, indicando que a modelagem inicial poderia subestimar a variabilidade real dos tempos de deslocamento.

Desse estudo, pode-se constatar que a técnica permitiu identificar variações que não foram detectadas por métodos tradicionais, melhorando a precisão das estimativas e a robustez dos modelos estatísticos utilizados. Assim, o uso do *bootstrap* foi eficaz na redução da incerteza em medições de confiabilidade do tempo de viagem. Isso sugere que a técnica pode ser amplamente aplicada para melhorar modelos de previsão no setor de transportes, fornecendo estimativas mais confiáveis para planejadores urbanos e gestores de tráfego (Yang e Cooke, 2018).

Benítez *et al.* (2014) aplicaram técnicas de *bootstrap* para estimar intervalos de confiança em matrizes origem-destino (OD) de transporte de cargas, utilizando dados de uma pesquisa nacional realizada na Espanha. O estudo teve como objetivo quantificar a incerteza dos dados coletados por meio de amostragens estatísticas e aprimorar a confiabilidade das matrizes OD derivadas dessas pesquisas. A metodologia permitiu gerar intervalos de confiança para cada par de origem e destino da matriz, fornecendo uma medida estatística da incerteza e possibilitando ajustes mais precisos na modelagem da demanda de transporte. Os resultados demonstraram que o uso dessa técnica na matriz OD reduziu a incerteza associada às estimativas, tornando-as mais representativas da realidade e melhorando sua aplicabilidade no planejamento de transporte de cargas.

Clark e McKimm (2005) compararam os métodos de Monte Carlo e *bootstrap* para estimar intervalos de confiança na participação modal do transporte em Leeds, Reino Unido.

Utilizando dados coletados em 2002, a simulação de Monte Carlo estimou um intervalo de confiança de 95% para a participação dos carros entre 58,9% e 61,7%, com um desvio-padrão de 0,71%. Posteriormente, o método de *bootstrap* foi aplicado a um conjunto de dados coletados em 2004, resultando em uma participação modal dos carros reduzida para 57,3% e um desvio-padrão ligeiramente menor (0,64%). A comparação entre os métodos mostrou que, embora ambos forneçam estimativas semelhantes, o *bootstrap* tende a gerar intervalos de confiança mais estreitos e pode ser mais preciso quando há um número limitado de amostras ou alta variabilidade diária.

5. MÉTODO

5.1. Considerações iniciais

Este capítulo descreve a metodologia adotada para atingir os objetivos desse trabalho e avaliar se as seis hipóteses estudadas se sustentam diante dos dados e evidências. Para isso, a metodologia está estruturada em duas etapas, sendo elas:

- Etapas comuns a todas as análises: responsáveis pela organização, integração e preparação dos dados para a aplicação dos testes estatísticos.
- Procedimentos específicos para cada grupo de hipóteses: estes procedimentos variam conforme os métodos estatísticos aplicados, adaptando-se às particularidades de cada conjunto de análises.

Do exposto, a estrutura metodológica apresentada no Fluxograma 1 (Figura 5.1) deve ser aplicada para avaliação de todas as seis hipóteses, uma vez são etapas comuns à todas as análises. O Fluxograma 2, mostrado na Figura 5.2, possui dois fluxos distintos: um destinado à análise das Hipóteses 1, 2 e 3, e outro voltado para as Hipóteses 4, 5 e 6. Essa diferenciação é necessária porque os testes estatísticos utilizados em cada conjunto de hipóteses são diferentes.

Figura 5.1 Fluxograma 1 – Etapas metodológicas comuns às hipóteses





Figura 5.2 Fluxograma 2 – Etapas metodológicas por conjunto de Hipóteses



Conforme mostra a Figura 5.2, o primeiro conjunto de hipóteses (1, 2 e 3) permite a avaliação global do comportamento dos motoristas, a partir da análise do percentual de tempo de permanência do condutor em diferentes faixas de velocidade, aceleração e frenagem, sem considerar as características individuais de cada motoristas. O segundo conjunto (Hipóteses 4, 5 e 6) investiga o desempenho individual de cada condutor, permitindo uma análise detalhada das variações na forma de condução de cada motorista, sob diferentes condições ambientais e de tráfego.

5.2 Etapas metodológicas comuns as Hipóteses

Essa estrutura metodológica garante a padronização das análises e possibilita tanto a investigação de padrões gerais entre os motoristas quanto a compreensão das variações individuais, oferecendo uma visão completa do impacto da ocorrência de precipitação, luminosidade e fluxo de veículos no comportamento de condução.

Assim, antes da aplicação dos procedimentos específicos para cada conjunto de hipóteses, é necessário seguir um conjunto de etapas metodológicas comuns, que permitem a coleta, organização e tratamento adequado dos dados meteorológicos e de condução. Essas etapas preliminares garantem confiabilidade às análises e possibilitam a padronização na forma de segmentação das viagens, de acordo as variáveis investigadas. A seguir, são apresentadas as etapas metodológicas comuns às seis hipóteses, conforme o Fluxograma mostrado na Figura 5.1.

Passo 1: Comitê de Ética em Pesquisa (CEP)

Nesta etapa, o projeto de pesquisa deve ser submetido ao Comitê de Ética em Pesquisa (CEP), uma vez que envolve a participação de seres humanos. Essa fase visa garantir que a pesquisa esteja em conformidade com princípios éticos estabelecidos, protegendo os direitos, a dignidade e o bem-estar dos participantes.

Passo 2: Coleta de dados

Para atender os objetivos do trabalho faz-se necessário coletar dois tipos de informações, são elas: (i) informações sobre o comportamento do condutor, tais como localização, velocidade, aceleração e frenagem; (ii) dados sobre a localização das estações meteorológicas do local em estudo.

No que tange aos dados dos condutores, essa metodologia está embasada nos Estudos Naturalísticos de Direção que coletam informações de condução em ambiente real sem interferências externas, proporcionando uma análise detalhada e precisa do comportamento dos motoristas. Tal estudo foi concebido conforme o princípio do “protótipo mínimo viável” que, segundo Borguezani *et al.* (2020), consiste em uma versão simplificada de um experimento ou pesquisa, podendo ser usada para coleta de dados e teste de hipóteses, sem incluir todas as variáveis ou funcionalidades investigadas.

Assim, para a coleta de dados faz-se necessário equipar os veículos particulares dos condutores participantes da pesquisa com os seguintes instrumentos:

- um notebook,
- um inversor de voltagem,
- um dispositivo GPS (*Global Positioning System*) e três câmeras, uma interna e duas externas.


Esses instrumentos coletam imagens e dados sobre o posicionamento e a velocidade dos veículos a cada segundo de viagem, sem gravação de áudio, a fim de preservar o condutor de uma exposição desnecessária para o objetivo do estudo (Borguezani *et al.*, 2020). O aparato utilizado e o posicionamento das câmeras estão presentes nas Figuras 5.3 e 5.4, respectivamente.

Figura 5.3 Esquema dos equipamentos utilizados



Fonte: Borguezani *et al.* (2020)

Figura 5.4 Posicionamento das Câmeras no interior do Veículo



Fonte: Borguezani *et al.* (2020)

A observação dos vídeos gravados e as informações armazenadas no GPS segundo a segundo inseridas em planilhas eletrônicas, do tipo Excel, são utilizadas para avaliação do comportamento do motorista. Entre esses dados tem-se:

- Identificação do motorista (código, para preservar sua identidade real);
- Latitude e longitude;
- Data e o horário de cada evento;
- Número da viagem para aquele motorista;
- Tempo acumulado na mesma viagem;
- Velocidade instantânea;
- Aceleração;

- h) Município;
- i) Bairro;
- j) Rua;
- k) Hierarquia da via segundo o plano diretor do município e o Código de Trânsito Brasileiro;
- l) Limite de velocidade da via.

Os equipamentos devem permanecer instalados e captando informações sobre o comportamento dos motoristas por cerca de duas semanas por condutor. A primeira viagem de cada condutor deve ser descartada, pois esse período serve para ambientação dos participantes da pesquisa quanto à presença dos equipamentos, especialmente às câmeras presentes no veículo.

Para tratamento dos dados, inicialmente deve-se inseri-los em planilhas eletrônicas do tipo Excel. Todavia, devido ao volume de informações a serem analisadas, recomenda-se a transferência dessas informações para *DataFrame* (tabelas) a serem analisadas na linguagem Python. Além de tratar vastos volumes de informações, essa ferramenta permite análise estatística, uma vez que dispõe de uma série de bibliotecas especializadas, como *SciPy* e *Statsmodels*, que facilitam a aplicação de modelos complexos.

No que se refere aos dados sobre a localização das estações meteorológicas do local em estudo, para identificação das estações pluviométricas deve-se consultar o portal do Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), hospedado no sítio eletrônico <http://www2.cemaden.gov.br/mapainterativo/#>.

O CEMADEN fornece informações referentes a precipitação de cada estação, com apresentação do seu código, nome, coordenadas geográficas, data e hora de aquisição do dado de precipitação, registrada de forma acumulada a cada 10 minutos, em caso de ocorrência de chuva, e a cada 1 hora, caso não esteja chovendo.

Passo 3: Conversão da localização da estação e do condutor para UTM (Universal Transverse Mercator)

Como as informações disponibilizadas pelo CEMADEN sobre as estações e os registros contínuos das posições dos condutores foram armazenadas em coordenadas geográficas, referenciadas por latitude e longitude, faz-se necessário realizar a conversão dessas coordenadas para o sistema UTM (Universal Transverse Mercator) para cálculos de distâncias.

Para tal, deve-se utilizar a biblioteca “*utm*” do Python, que contém funções especializadas para converter coordenadas em graus decimais para o formato UTM. A conversão deve ser aplicada a cada registro do *DataFrame*, e as novas coordenadas devem ser armazenadas em colunas adicionais.

Posteriormente, deve-se definir a estação mais próxima do condutor a cada segundo, utilizando a função “*cdist*” da biblioteca “*scipy*”. Essa função calcula a distância euclidiana entre as coordenadas UTM de cada estação e as coordenadas UTM registradas pelo veículo ao longo do tempo. A cada segundo, deve ser calculada a menor distância entre o veículo e as estações, e em uma nova coluna do *DataFrame*, denominada “Estação Mais Próxima”, deve-se registrar o nome da estação mais próxima.

Passo 4: Combinação dos dados meteorológicos e de condução

Em virtude da discrepância nas unidades de registro dos dados de precipitação que são coletados a cada 10 minutos durante eventos pluviométricos ou a cada 1 hora em períodos sem chuva em contraste com os dados de condução, que são registrados a cada segundo, faz-se necessário estabelecer um procedimento de integração eficaz das informações. Assim, assumiu-se que a precipitação registrada a cada segundo é equivalente ao valor observado pela estação meteorológica mais próxima do veículo no instante da medição mais próxima ao evento em questão. Essa abordagem permite uma harmonização dos dados, garantindo a consistência temporal entre as medições pluviométricas e os registros de condução.

Para combinar as informações temporais das estações meteorológicas com os dados do condutor, deve-se utilizar dados disponíveis em duas planilhas:

1. Planilha 1 (Informações dos condutores): contém as colunas 'Estação Mais Próxima', 'Data' e 'Hora' (s), representando a localização e o tempo de cada registro dos veículos.
2. Planilha 2 (Dados de Precipitação): contém as colunas 'Estação', 'Data', 'Hora', e 'Quantidade de Precipitação (mm)', com o volume de chuva nas estações pluviométricas ao longo do tempo (10 em 10min ou de hora em hora).

Para integração dos dados recomenda-se utilizar a função *pd.merge* da biblioteca *pandas*, que permite combinar dois conjuntos de dados (*DataFrames*) com base em uma chave comum, neste caso a coluna 'Estação'. Essa junção possibilita que cada registro de viagem seja associado ao dado de precipitação mais próximo da respectiva estação meteorológica. Assim, deve ser inserida no *DataFrames* (Informações dos condutores) uma nova coluna denominada

"quantidade mm" com o volume de precipitação registrado pelo CEMADEN da estação mais próxima do condutor a cada segundo de sua viagem.

Passo 5: Classificação das condições meteorológicas:

Para classificação das condições meteorológicas, deve-se observar a quantidade de viagens realizadas em diferentes intensidades de chuva a fim de observar que os dados disponíveis permitem análises estatísticas precisas. Pode-se adotar, por exemplo, a classificação das condições meteorológicas utilizada por Faria *et al.*, (2020) no qual considera-se:

- Sem Chuva: Precipitação igual a 0 mm.
- Chuva Leve: Precipitação entre 0 e 0,5 mm.
- Chuva Moderada: Precipitação entre 0,5 mm e 4 mm.
- Chuva Forte: Precipitação superior a 4 mm.

Quando se observa uma concentração desproporcional de amostras em algumas classes, há comprometimento nas análises estatísticas. Dessa forma, pode-se simplificar a classificação meteorológica, consolidando-a em apenas duas categorias principais:

- sem chuva: inclui todos os registros onde a precipitação foi igual a 0 mm.
- com chuva: abrange todos os registros com qualquer quantidade de precipitação superior a 0 mm.

Assim, após a escolha da classificação a ser utilizada, a partir do registro da coluna "quantidade mm" no *DataFrame*, classifica-se cada segundo de viagem e insere esta informação em uma nova coluna denominada "condição".

Passo 6: Divisão das viagens como base nas mudanças climáticas

A análise da coluna "condição" no *DataFrame* permite identificar o momento em que ocorreu a transição entre as classificações das condições meteorológicas adotadas, por exemplo, de "sem chuva" para "com chuva", ou vice-versa. Quando o veículo atravessa essa fronteira climática, a viagem original deve ser segmentada, resultando em uma nova viagem (subviagem). Isso permite uma análise isolada das métricas de desempenho do veículo, como velocidade, aceleração e frenagem, para cada fase da viagem, considerando as classificações das condições meteorológicas adotadas.

Passo 7: Classificação das subviagens em Diurno ou Noturno e Pico ou entre picos

Para distinguir os períodos da subviagem em diurno ou noturno e investigar as possíveis alterações no comportamento do condutor em função da luminosidade natural, faz-se necessário classificar os dados em dois grupos principais: períodos diurnos (D) e noturnos (N).

A categorização dos períodos diurno e noturno deve ser realizada com base nos horários de nascer e pôr do sol da(s) cidade(s) em estudo durante o período de coleta de dados. O site: <https://www.sunrise-and-sunset.com/pt/sun/brasil/curitiba/> fornece o histórico dos horários diários de nascer e pôr do sol. Após coletados, esses dados devem ser organizados em uma tabela e integrados ao *DataFrame* por meio de um script desenvolvido em Python. Esse script automatiza o processo de cruzamento entre os horários de início de cada subviagem e os respectivos horários de nascer e pôr do sol, permitindo assim a categorização de cada viagem como "diurno" ou "noturno".

No que tange ao horário de pico, o comportamento dos motoristas foi analisado em relação aos horários de pico (períodos de maior volume de tráfego) e entre picos (períodos com menor fluxo de veículos). Para tal, considerou os horários de pico entre 07:00 e 08:00 e entre 18:00 e 19:00. Os demais horários foram tratados como "entre picos", de modo a facilitar a segmentação das viagens nesses períodos específicos.

5.3 Procedimento Metodológico aplicável para análise globalizada do Comportamento dos Condutores - HIPÓTESES 1, 2 e 3:

Os passos descritos a seguir possibilitam uma avaliação global do comportamento dos condutores, por meio da análise do percentual de tempo de permanência em diferentes faixas de velocidade, aceleração e frenagem. Dessa forma, propõe-se uma abordagem metodológica que permite comparar os padrões gerais de condução sob diferentes condições climáticas (chuva e sem chuva) e nos períodos diurnos e noturnos e de pico e entre picos, sob chuva.

A metodologia proposta permite identificar a influência de cada uma dessas variáveis ambientais e de tráfego no percentual de tempo em que os motoristas permanecem em determinadas faixas de velocidade, aceleração e frenagem, possibilitando a compreensão das tendências coletivas no comportamento de condução da amostra estudada. Esse procedimento envolve a aplicação de testes estatísticos para verificação da existência de diferenças significativas entre as condições analisadas, a fim de compreender seus efeitos na mobilidade e na segurança viária.

A seguir são descritas as etapas do procedimento metodológico proposto para análise globalizada do Comportamento dos Condutores aplicável às hipóteses 1, 2 e 3.

A: Cálculo das porcentagens de tempo de permanência em cada faixas de velocidade, aceleração e frenagem – Hipóteses 1, 2 e 3

Após a subdivisão das viagens (baseadas na condição climática), deve ser implementado um código no *Python* para calcular as porcentagens de tempo que os condutores passam por diferentes faixas de comportamento durante essas subviagens, no que tange a variações na velocidade, aceleração e frenagem. Para tal, utiliza-se as seguintes colunas presentes na planilha dos condutores:

- SPD_MPH: Velocidade do veículo em milhas por hora.
- SPD_KMH: Velocidade do veículo em quilômetros por hora.
- ACCEL_MS2: Aceleração do veículo em metros por segundo ao quadrado.
- LIMITE_VEL: Limite de velocidade da via em que o veículo estava trafegando.

A fim de avaliar o comportamento dos condutores, devem ser estabelecidas categorias para investigação conforme variações na velocidade, na aceleração e na frenagem. Neste sentido, sugere-se a adoção das seguintes categorias:

Velocidade:

- V1: Percentagem de tempo com velocidade mais que 10% menor do que a velocidade máxima permitida na via
- V2: Percentagem de tempo com velocidade entre 10% menor e 10% maior que a velocidade máxima permitida na via
- V3: Percentagem de tempo com velocidade mais que 10% maior do que a velocidade permitida máxima permitida na via

Aceleração:

- A1: Percentagem de tempo com acelerações normais ($0 \text{ m/s}^2 \leq \text{aceleração} \leq 1,5 \text{ m/s}^2$).
- A2: Percentagem de tempo com acelerações abruptas ($\text{aceleração} > 1,5 \text{ m/s}^2$).

Frenagem:

- F1: Percentagem de tempo com frenagens normais ($-1,5 \text{ m/s}^2 \leq \text{aceleração} \leq 0 \text{ m/s}^2$).

- F2: Percentagem de tempo com frenagens abruptas (aceleração $< -1,5 \text{ m/s}^2$).

Em função das variáveis de velocidade, aceleração e frenagem do veículo durante cada subviagem, deve-se calcular a percentagem de tempo em que os condutores permanecem em cada uma das condições previamente mencionadas. Assim, é possível obter sete métricas: V1, V2, V3, A1, A2, F1 e F2, representando, respectivamente, as percentagens de tempo total da subviagem associadas às diferentes categorias de velocidade, aceleração e frenagem. A soma das percentagens para cada categoria de velocidade (V1, V2 e V3) deve totalizar 100%. Da mesma forma, a soma das percentagens relativas à aceleração e frenagem (A1, A2, F1 e F2) deve igualmente atingir 100%.

Os resultados das percentagens calculadas para cada uma dessas categorias devem ser integrados ao *DataFrame* principal, permitindo uma análise abrangente dos segmentos de viagem com base nas condições meteorológicas e comportamentais. Posteriormente, o *DataFrame* final deve ser exportado para um novo arquivo do tipo CSV ou Excel, onde as subviagens e suas respectivas percentagens devem ser registradas.

Nesta perspectiva, esse estudo pressupõe comportamento homogêneo dos condutores ao dirigir, uma vez que não são considerados os aspectos individuais do motorista, tais como experiência, estilo de direção, preferências pessoais ou outras características que possam influenciar a forma como cada um dirige.

B: Identificação da quantidade de amostra por categoria investigada

Tempos de viagens muito curto, não são suficientes para a adaptação do comportamento de condução às diferentes condições de tráfego e clima (TAKANO, 2011). Dessa forma, podem deixar de registrar variações na conduta entre períodos de chuva e tempo seco, bem como entre viagens realizadas de dia e à noite, nos horários de pico e entre picos. Por esses motivos, recomenda-se que as subviagens com duração inferior a 30 segundos sejam desconsideradas.

Após estas exclusões, deve-se determinar a quantidade de subviagens válidas (amostra) e categorizá-las em: (i) com chuva e sem chuva, (ii) diurno ou noturno, com chuva e (iii) Pico e entre picos, com chuva.

C: Resultados, Análises e Discussões

Os resultados, as análises e discussões devem ser apresentados para cada hipótese.

- Estatísticas Descritivas

Nesta etapa propõe-se a realização de uma análise exploratória dos dados por meio de estatística descritiva, separando os grupos estudados em cada hipótese, sendo eles: (i) com chuva e sem chuva, (ii) diurno ou noturno, com chuva e (iii) pico e entre picos, com chuva.

Para cada um desses grupos, deve-se calcular a média, a mediana e o desvio padrão para as variáveis V1, V2, V3, A1, A2, F1, F2. Esse procedimento permite uma caracterização inicial dos dados, destacando diferenças entre as condições analisadas e auxiliando na compreensão preliminar do comportamento destas variáveis.

- Construção dos *Boxplots*

Nesta etapa, os resultados devem ser apresentados por meio de gráficos do tipo *Boxplot*, nos quais a distribuição dos dados é ilustrada, destacando-se a mediana, os quartis e possíveis valores discrepantes (*outliers*). A geração desses gráficos deve ser realizada por meio da linguagem de programação do tipo Python, com a utilização das bibliotecas *Seaborn* e *Matplotlib*.

Para cada conjunto de dados estudados, recomenda-se a construção *Boxplots* que representam as variáveis de interesse, incluindo velocidade, aceleração e frenagens, sendo os grupos V, A e F considerados separadamente. Essa abordagem permite a avaliação comparativa entre os grupos estudados.

- Aplicação do teste de Normalidade

Além da análise visual dos dados por meio do *boxplot*, recomenda-se a aplicação de um procedimento sistêmico de testes estatísticos para garantir que as conclusões sejam embasadas em evidências quantitativas. Inicialmente deve-se aplicar o teste de normalidade, uma vez que ele permite determinar se os dados seguem uma distribuição normal.

Nos casos em que a amostra é superior a 50 elementos, recomenda-se a aplicação do teste de D'Agostino-Pearson. O teste de Shapiro-Wilk é adequado para amostras que possuem menos de 50 observações, pois apresenta maior sensibilidade a desvios da normalidade em conjuntos de dados pequenos. A escolha do teste de segurança garante uma avaliação mais precisa da distribuição dos dados, permitindo a seleção correta dos testes estatísticos subsequentes, como testes paramétricos ou não paramétricos.

Assim, deve-se aplicar o teste de normalidade de Shapiro-Wilk ou D'Agostino-Pearson, conforme tamanho da amostra, a fim de testar as seguintes hipóteses:

H0: Se o p-valor for superior a 0,05, considera-se que o conjunto de dados apresenta distribuição normal.

H1: Se o valor-p for inferior a 0,05, considera-se que o conjunto de dados apresenta distribuição não-normal.

No Python, o teste de Shapiro-Wilk é implementado com o auxílio da biblioteca “SciPy”, especificamente o módulo *scipy.stats*, que possui a função “*stats.shapiro*”. No caso do teste de D'Agostino-Pearson, a biblioteca empregada é a “*stats.normaltest*”. A aplicação destes testes retorna dois valores fundamentais: a estatística do teste e o p-valor, sendo este último usado para decidir se aceita ou rejeita-se a hipótese nula (H0) em relação à normalidade dos dados.

- O processo de Reamostragem

O método *bootstrap* é usado para garantir estimativas mais representativas da variabilidade observada no ambiente real e permite avaliar propriedades de grandes amostras reamostradas a partir de um conjunto limitado de observações (Alves, 2013).

Dessa forma, estudos que apresentam limitações no tamanho da amostra devem recorrer ao *bootstrap* para aprimorar a representatividade dos resultados. A fim de comparar os efeitos dessa abordagem, este estudo investiga o comportamento dos motoristas considerando dois perfis de amostra: (i) a amostra original e (ii) a amostra obtida por meio do processo de reamostragem.

A amostra original corresponde aos dados coletados por meio do estudo naturalístico de direção, que analisa o comportamento dos motoristas em seu ambiente real, sem interferências externas.

A técnica de reamostragem *bootstrap* consiste na geração de novas amostras a partir de uma amostra original, utilizando sorteios com reposição. Embora esse processo produza múltiplos subconjuntos para análise, todos permanecem representativos do comportamento original dos motoristas, uma vez que os dados reamostrados são derivados dos valores inicialmente observados (Alves, 2013).

Além de aprimorar a precisão das estimativas, a técnica *bootstrap* também viabiliza a construção de intervalos de confiança mais apurados e representativos da variabilidade dos dados. De acordo com Kvam *et al.* (2022), vários métodos podem ser empregados para a estimativa de níveis de confiança por meio do *bootstrap*, entre os quais se destacam: o intervalo de confiança *bootstrap* padrão, *bootstrap*-t, percentil, percentil corrigido pelo viés (BCPB) e o intervalo de confiança corrigido pelo viés acelerado (BCa). A Tabela 4.1, apresentada no referencial teórico, detalha as principais características de cada deles, incluindo suas vantagens, limitações e aplicações. As informações constantes nesta tabela devem ser utilizadas como instrumento para escolha do método adequado para cada caso estudado, considerando o resultado do teste de normalidade.

Para a amostra gerada via *bootstrap*, a fim de avaliar sua confiabilidade, recomenda-se calcular o Intervalo de Confiança (IC) e a Amplitude (A), a fim de garantir uma estimativa robusta da variabilidade dos dados. A escolha do método para estimar o IC deve ser realizada com base nos resultados do teste de normalidade e nas recomendações apresentadas na Tabela 4.1.

Nesse contexto, para aplicação técnica *bootstrap* recomenda-se o uso *Python*, com auxílio das bibliotecas: Pandas, para manipulação e organização dos dados; NumPy para reamostragem com reposição e cálculos estatísticos; Statsmodels para estimativa dos intervalos de confiança, tanto paramétricos quanto não paramétricos; e Seaborn para visualização gráfica da distribuição dos dados e dos resultados estatísticos.

Para a amostra original, a escolha do método para estimar o intervalo de confiança (IC) deve ser determinada com base nos resultados do teste de normalidade mencionado anteriormente. Se os dados seguirem uma distribuição normal, o IC será estimado por um método paramétrico, utilizando a média e o desvio padrão como estatísticas descritivas. Nessa condição, o teste t pareado é recomendado para avaliar a diferença entre as amostras, pois compara as médias das diferenças sob a suposição de normalidade dos erros.

Quando os dados não atendem ao pressuposto de normalidade, a estimação do intervalo de confiança deve ser realizada por meio de métodos não paramétricos. Nessa situação, o estimador de *Hodges–Lehmann* é definido como a mediana de todas as diferenças possíveis entre pares de observações. Esse procedimento fornece uma medida da diferença típica entre duas amostras, aplicável mesmo em distribuições populacionais desconhecidas. De acordo com Hodges e Lehmann (1963), o estimador representa uma alternativa eficaz aos métodos

paramétricos, como o teste t pareado, permitindo obter resultados consistentes em situações nas quais a suposição de normalidade não pode ser assegurada.

- Fluxograma dos Testes Estatísticos para Velocidade

A Figura 5.4 mostra o fluxograma utilizado para comparação dos percentuais de tempo de permanência em cada faixa de velocidade, considerando os diversos cenários investigados. Esse procedimento deve ser aplicado quando são avaliados três ou grupos, como é o caso da velocidade (V1, V2 e V3).


Conforme tal fluxograma, após as amostras passarem pelos testes de normalidade supracitados, testes subsequentes devem ser realizados de acordo com o grupo de análise.

Se os dados seguirem normalidade ($p\text{-valor} > 0,05$), aplica-se o teste ANOVA, que avalia se há diferenças significativas entre as médias dos grupos. Se os dados não apresentarem normalidade ($p\text{-valor} < 0,05$), utiliza-se o teste de *Kruskal-Wallis*, uma alternativa não paramétrica à ANOVA. Em ambos os casos, o $p\text{-valor}$ orienta a interpretação dos resultados:

H0: quando $p\text{-valor} > 0,05$, não há diferença estatística entre o par de conjuntos amostrais testados;

H1: quando $p\text{-valor} < 0,05$, há diferença estatística entre o par de conjuntos amostrais testados.

Figura 5.4 Fluxograma para comparação mais de dois grupos



Quando o teste é significativo ($p\text{-valor} \leq 0,05$) pelo menos um dos grupos apresenta uma distribuição diferente. Todavia, os testes de ANOVA e *Kruskal-Wallis* não informam os grupos que apresentam diferenças entre si. Para isso, é necessário realizar um teste post hoc, como o de *Dunn* ou *Tukey*, que permite identificar os pares que possuem diferenças estatisticamente significativas.

Se o teste de *Kruskal-Wallis* indicar diferenças significativas entre os grupos, recomenda-se a utilização do teste de *Dunn*, adequado para comparações múltiplas em dados não paramétricos.

Como essa abordagem envolve múltiplas comparações, há um risco de cometer um erro tipo I – que ocorre quando rejeitamos incorretamente a hipótese nula e identificamos uma diferença inexistente. Para minimizar esse erro, recomenda-se a aplicada uma correção estatística, como *Holm* ou *Bonferroni*, garantindo um controle adequado sobre as comparações.

Caso os dados apresentem distribuição normal e a ANOVA aponte diferenças significativas entre os grupos, recomenda-se a aplicação do teste de *Tukey*, que é apropriado para comparações múltiplas em dados paramétricos. Esse teste permite identificar os grupos diferem entre si, ajustando automaticamente os p-valores para manter o controle sobre o erro tipo I.

Após a aplicação do teste apropriado (*Tukey* ou *Dunn*), recomenda-se a realizada a análise estatística entre os pares de grupos para verificar diferenças significativas e interpretar os resultados. Nesse sentido se?

H0: quando $p\text{-valor} > 0,05$, não há diferença estatística entre o par de conjuntos amostrais testados;

H1: quando $p\text{-valor} < 0,05$, há diferença estatística entre o par de conjuntos amostrais testados.

O teste de *Tukey* fornecesse o p-valor e a estatística q que representa a diferença padronizada entre as médias dos grupos analisados, considerando a variabilidade dentro dos grupos. Quanto maior o valor de q , maior a diferença entre os grupos em relação à dispersão dos dados.

No que tange ao teste de *Dunn*, além do $p\text{-valor}$ ajustado (*Holm* ou *Bonferroni*), outro parâmetro utilizado na interpretação dos resultados é o valor Z que representa a estatística

padronizada utilizada para comparar as medianas dos grupos analisados. Quanto maior o valor absoluto de Z, maior a diferença entre os grupos.

Para aplicação destes testes estatísticos recomenda-se o uso *Python*, com auxílio das bibliotecas *Pandas*, *NumPy*, *Statsmodels*, *Scikit-posthocs*, *SciPy* e *Seaborn*, cujas funções foram supracitadas.

- Fluxograma dos Testes Estatísticos para Aceleração e Frenagem

A Figura 5.5 mostra o fluxograma utilizado para comparação dos percentuais de tempo de permanência em cada faixa de aceleração e frenagem, considerando que são comparados dois grupos (A1 e A2; F1 e F2).


Inicialmente aplica-se teste de Normalidade, conforme supracito. Em seguida, para comparação dos grupos A e F (dois conjuntos cada), o teste *t-Student* ($\alpha = 0,05$) (caso verificada normalidade) ou *U-Mann-Whitney* ($\alpha = 0,05$) (caso não verificada normalidade) deve ser aplicado, para verificar se há diferença significativa entre os diferentes parâmetros. O par de hipóteses a ser testado é:

H0: quando $p\text{-valor} > 0,05$, não há diferença estatística entre os dois conjuntos amostrais testados;

H1: quando $p\text{-valor} < 0,05$, há diferença estatística entre os dois conjuntos amostrais testados.

Para aplicação destes testes estatísticos recomenda-se o uso *Python*, com auxílio das bibliotecas *Pandas*, *NumPy*, *Statsmodels*, *SciPy* e *Seaborn*, cujas funções foram supracitadas.

Figura 5.5: Fluxograma para comparação entre dois grupos



5.4 Procedimento Metodológico aplicável para análise individualizada do Comportamento dos Condutores - HIPÓTESES 4, 5 E 6:

Os passos descritos a seguir possibilitam a análise individualizada da variação da velocidade, da aceleração e da frenagem de cada condutor. Esse procedimento compara padrões de condução de cada motorista sob diferentes condições climáticas (chuva e sem chuva), nos períodos diurnos e noturnos e nos períodos de pico e entre picos, sob chuva. O uso desta metodologia permite identificar como cada fator influencia o comportamento individual dos condutores e possibilita a aplicação de testes estatísticos para verificar a existência de diferenças entre as categorias estudadas.

A metodologia proposta permite identificar a influência de cada uma dessas variáveis ambientais e de tráfego no percentual no que tange a velocidade relativa, aceleração e frenagem, possibilitando a compreensão das tendências individuais no comportamento de condução da amostra estudada. Esse procedimento envolve a aplicação de testes estatísticos para verificação da existência de diferenças significativas entre as condições analisadas, a fim de compreender seus efeitos na mobilidade e na segurança viária.

A seguir são descritas as etapas do procedimento metodológico proposto para análise individualizado do Comportamento de cada condutor aplicável às hipóteses 4, 5 e 6.

A: Amostras

A amostra deve ser apresentada com base no tempo de viagem em que cada condutor permaneceu em cada condições avaliadas, sendo elas: (i) com chuva e sem chuva, (ii) diurno ou noturno, com chuva e (iii) Pico e entre picos, com chuva.

Para incluir um motorista na análise, é necessário que ele tenha realizado viagens em todas as situações avaliadas, garantindo uma comparação adequada entre as diferentes condições. Dessa forma, a seleção dos condutores que compõem a amostra considera os seguintes critérios:

- Para avaliar o efeito na condução, o motorista precisa realizar viagens tanto em condições de chuva quanto sem chuva.
- Para analisar a influência da luminosidade, sob planejamento, o condutor deveria ter realizado mudanças durante o dia e a noite, ambos sob chuva.

- Para investigar os efeitos da variação no fluxo de veículos, sob chuva, o motorista deveria ter realizado viagens nos períodos de pico e entre picos, ambos sob chuva.

Esta análise considera que os padrões de condução são influenciados pelas condições reais das vias percorridas, refletindo aspectos do tráfego, da infraestrutura e do clima no comportamento do condutor. Embora os dados capturem variações naturais na condução, é necessário considerar que as trajetórias escolhidas podem apresentar características específicas que impactam as diferenças observadas.

Dessa forma, um motorista que trafega no período de pico pode optar por rotas com baixo fluxo veicular, reduzindo o impacto da alta demanda no tráfego no seu comportamento. Da forma análoga, no período noturno, a presença de iluminação artificial em determinadas vias pode minimizar os efeitos da baixa luminosidade na condução.

Para identificação dos condutores que pertencem a amostra, bem como para determinação do tempo que cada motorista permaneceu nas condições em investigação, recomenda-se o uso da linguagem de programação *Python*, especialmente a bibliotecas *Pandas*.

B: Cálculo das Velocidades

Para analisar individualmente o comportamento dos motoristas em relação ao limite máximo de velocidade sob diferentes condições climáticas (com chuva e sem chuva), recomenda-se o uso de uma abordagem que analisa a velocidade relativa adotada por cada motorista a cada segundo de viagem. Assim, a velocidade relativa é calculada pela seguinte equação:

$$Velocidade\ Relativa = \frac{Velocidade\ Instantanea - Velocidade\ Limite}{Velocidade\ Limite} \quad \text{Equação (1)}$$

Onde:

- Velocidade Relativa $< 0 \rightarrow$ O motorista está dirigindo abaixo do limite máximo de velocidade da via.
- Velocidade Relativa $> 0 \rightarrow$ O motorista está acima do limite máximo de velocidade da via.
- Velocidade Relativa $= 0 \rightarrow$ O motorista está exatamente no limite máximo de velocidade da via.

Do exposto, essa análise permite identificar se o motorista adota um comportamento mais prudente, mantendo-se abaixo do limite máximo de velocidade da via, ou mais arriscado, ultrapassando o limite estabelecido.

C: Resultados, Análises e Discussões

- Estatística Descritiva

Para caracterizar os padrões de velocidade, aceleração e frenagem recomenda-se calcular as médias, as medianas e os desvios padrões para cada condição estudada. Esses indicadores permitem verificar a distribuição dos dados, a variabilidade dos comportamentos individuais e possíveis discrepâncias entre as situações investigadas neste estudo (chuva e sem chuva; diurno e noturna, sob chuva; e pico e entre pico, sob chuva).

Além disso, recomenda-se a geração de *boxplots* para visualizar a dispersão dos dados e a presença de *outliers*, facilitando a identificação de padrões na resposta dos motoristas às diferentes condições avaliadas.

O tratamento dos dados deve ser realizado utilizando a linguagem *Python* com auxílio das bibliotecas *Pandas*, *Numpy* e *Matplotlib*.

- Construção dos *Boxplots*

Para a análise do comportamento dos condutores sob diferentes situações investigadas, recomenda-se utilizar *boxplots*, uma ferramenta estatística que permite visualizar a distribuição dos dados, facilitando a identificação de tendências centrais, dispersão e a presença de valores atípicos (*outliers*). Esse método gráfico pode-se empregar em estudos sobre comportamento veicular, pois auxilia na interpretação das variações nas métricas analisadas, como velocidade, aceleração e frenagem.

A interpretação dos *boxplots* deve-se realizar em conjunto com a estatística descritiva (médias, medianas e desvios padrão) a fim de identificar mudanças no comportamento dos condutores em resposta às condições climáticas e ao fluxo de tráfego, contribuindo para a validação das hipóteses do estudo.

- Aplicação do Teste de Normalidade

Inicialmente aplica-se teste de Normalidade. Nos casos em que a amostra é maior ou igual a 50 elementos, deve-se aplicar o teste de D'Agostino-Pearson e quando a mostra possui menos de 50 observações sugere-se utilizar o teste de Shapiro-Wilk, a fim de testar as seguintes hipóteses:

H0: Se o p-valor for superior a 0,05, considera-se que o conjunto de dados apresenta distribuição normal.

H1: Se o valor-p for inferior a 0,05, considera-se que o conjunto de dados apresenta distribuição não-normal.

No Python, o teste de Shapiro-Wilk é implementado com o auxílio das bibliotecas: “*SciPy*” e “*stats.shapiro*”. No caso do teste de D'Agostino-Pearson, a biblioteca empregada é a “*stats.normaltest*”.

- Aplicação dos Paramétricos e Não Paramétricos

Em seguida, para comparação do comportamento de cada condutor quanto às seguintes situações: (i) Hipótese 4: chuva e sem chuva; (ii) Hipótese 5: diurno e noturno, ambos sob chuva e (iii) Hipótese 6: pico e entre picos, ambos sob chuva, aplica-se o teste *t-Student* ou *U-Mann-Whitney*, uma vez que esses grupos investigados contemplam apenas 2 elementos.

O teste *t-Student* ($\alpha = 0,05$), conforme 5.6 supracitado, deve ser aplicado quando é verificada normalidade e o *U-Mann-Whitney* ($\alpha = 0,05$) quando não se verifica normalidade. O par de hipóteses a ser testado é:

H0: quando p-valor $> 0,05$, não há diferença estatística entre os dois conjuntos amostrais testados;

H1: quando p-valor $< 0,05$, há diferença estatística entre os dois conjuntos amostrais testados.

Para aplicação destes testes estatísticos recomenda-se o uso *Python*, com auxílio das bibliotecas *Pandas*, *NumPy*, *Statsmodels*, *SciPy* e *Seaborn*, cujas funções foram supracitadas.

6. ESTUDO DE CASO: COMPORTAMENTO DOS CONDUTORES DE CURITIBA

6.1. Comitê de Ética em Pesquisa (CEP)

Esta pesquisa faz parte de um projeto em andamento na Universidade Federal do Paraná (UFPR), aprovado pelo Comitê de Ética em Pesquisa (CEP) do setor de Ciências da Saúde da UFPR. O CEP do Instituto Federal de Goiás (IFG) foi consultado e este projeto foi incluído como instituição coparticipante do projeto em andamento aprovado pelo CEP da Universidade Federal do Paraná.

6.2 Coleta de dados

Para atender os objetivos do trabalho foi necessário coletar informações sobre o comportamento do condutor e sobre a localização das estações meteorológicas do local em estudo.

No que tange aos dados dos condutores, as informações utilizadas neste trabalho foram coletadas de forma contínua desde 2019 no município de Curitiba-PR e região metropolitana, mais especificamente nos períodos mostrados na Tabela 6.1.

Tabela 6.1. Período de monitoramento, quantidade e tempo de viagens dos condutores

Condutor	Período de monitoramento	Quantidade de viagens válidas	Tempo de viagens válidas (h)
1	17/09/2021 - 29/09/2021	7	0,4
2	12/10/2021 - 25/10/2021	4	0,17
3	13/10/2021 - 16/10/2021	6	1,02
4	29/10/2021 - 15/11/2021	7	0,82
5	11/11/2021 - 25/11/2021	19	7,4
6	28/11/2021 - 04/12/2021	28	5,03
7	09/08/2019 - 17/09/2019	9	1,92
8	23/09/2019 - 23/09/2019	1	0,18
9	29/10/2019 - 13/11/2019	7	8,32
10	06/07/2021 - 07/07/2021	3	0,55
11	29/07/2021 - 12/08/2021	21	5,93
12	01/08/2021 - 12/08/2021	31	26,58
13	16/08/2021 - 27/08/2021	23	14,43
14	20/08/2021 - 02/09/2021	4	0,37
15	27/08/2019 - 03/09/2019	5	0,18
16	09/08/2019 - 09/08/2019	1	0,02
17	21/11/2020 - 08/12/2020	30	13,93
18	23/11/2020 - 04/12/2020	31	17,72
19	12/12/2020 - 20/12/2020	12	3,22
20	11/01/2021 - 24/01/2021	58	12,38
21	26/01/2021 - 29/01/2021	12	1,07
22	15/02/2021 - 18/02/2021	6	0,68
23	20/02/2021 - 05/03/2021	25	4,2
24	24/05/2021 - 06/06/2021	17	2,35
25	24/05/2021 - 07/06/2021	62	10,47

26	09/06/2021 - 21/06/2021	21	8,25
27	23/06/2021 - 09/07/2021	15	2,87
28	23/09/2019 - 29/09/2019	31	64,92
29	30/09/2019 - 08/10/2019	23	103,07
30	19/01/2021 - 21/01/2021	9	5,22
31	03/09/2021 - 16/09/2021	15	3,1
TOTAL		543	326,77

Para coleta de dados foi necessário equipar os veículos particulares dos condutores participantes da pesquisa com notebook, inversor de voltagem, dispositivo GPS (*Global Positioning System*) e três câmeras, uma interna e duas externas. Esses equipamentos não gravavam áudio para preservar o condutor. O aparato utilizado e o posicionamento das câmeras foram semelhantes aos apresentados nas Figuras 5.2 e 5.3, respectivamente.


A observação dos vídeos gravados e a extração das informações armazenadas no GPS permitem identificar: o motorista (código, para preservar sua identidade real); a latitude e a longitude do veículo; a data e o horário de cada evento; o número da viagem para aquele motorista; o tempo acumulado na mesma viagem; a velocidade instantânea; a aceleração; o município; o bairro; a rua; a hierarquia da via segundo o plano diretor do município e o Código de Trânsito Brasileiro; a velocidade máxima permitida na via, entre outros.

Os equipamentos permaneceram instalados e captando informações sobre o comportamento dos motoristas por cerca de duas semanas por condutor. Até junho de 2023, a pesquisa já havia recrutado e coletado dados de mais de 50 condutores. As viagens foram realizadas em Curitiba e Região Metropolitana, no estado do Paraná, Brasil. A primeira viagem de cada condutor foi descartada, pois esse período foi usado para ambientação dos participantes da pesquisa quanto à presença dos equipamentos, especialmente às câmeras.

Os dados coletados sobre o condutor foram compilados em planilhas eletrônicas tipo Excel, e posteriormente inseridas em um *DataFrame* por meio da biblioteca *pandas* presente na linguagem *Python*. Essa biblioteca é utilizada para análises de grandes volumes de dados em estruturas semelhantes a planilhas, otimizando o processamento e a organização das informações coletadas.

No que se refere aos dados sobre a localização das estações meteorológicas de Curitiba-PR, foi realizada uma consulta ao portal do CEMADEN (Centro Nacional de Monitoramento e Alertas de Desastres Naturais) onde foi possível identificar cada estação meteorológicas de referido município, conforme mostra a Figura 6.1.

Figura 6.1. Estações Pluviométrica presentes em Curitiba



Além disso, o CEMADEN fornece informações referentes a precipitação de cada estação, com apresentação do seu código, nome, coordenadas geográficas, data e hora de aquisição do dado de precipitação, registrada de forma acumulada a cada 10 minutos, em caso de ocorrência de chuva, e a cada 1 hora, caso não esteja chovendo. A Tabela 6.2 apresenta o nome e as coordenadas geográficas (latitude e longitude) das 9 estações meteorológicas localizadas em Curitiba.

Tabela 6.2. Latitude e Longitude das Estações Pluviométricas de Curitiba

Nome da Estação	Latitude	Longitude
Butiatuvinha	-25,4112	49,3618
Atuba	-25,384	49,197
Boa Vista	-25,379	49,245
Cachoeira	-25,3536	49,2553
Pilarzinho	-25,38	49,295
Santa Felicidade	-25,382	49,332
São Braz	-25,417	49,342
Umbará	-25,555	49,284
Vista Alegre	-25,413	49,301

Essas coordenadas também foram inseridas em um *DataFrame* por meio da biblioteca *pandas* da linguagem *Python*, para posterior análise.

6.3 Conversão da localização da estação e do condutor para UTM (Universal Transverse Mercator)

Como indicado anteriormente, tanto os dados obtidos no CEMADEN sobre localização das estações quanto à localização dos condutores a cada segundo são fornecidos por meio de latitude e longitude. Todavia, para realizar cálculos de distâncias, é necessário converter tais informações para o sistema de coordenadas UTM (Universal Transverse Mercator). Essas conversões foram implementadas utilizando a biblioteca “*utm*” do “*Python*”, que fornece funções especializadas para a transformação de coordenadas em graus decimais (latitude e longitude) para o sistema UTM. A Tabela 6.3 mostra um recorte dos resultados encontrados nesse processo para a localização dos condutores.

Tabela 6.3. Transformação de Latitude e Longitude em UTM (localização do condutor)

DRIVE	LONG	SPD_MPH	SPD_KMH	ACEL_MS2	ERARQUIA	LIMITE_Y	UTM_E	UTM_N
Y	-49,2503	26,22857776	42,211	0,006	3	40	675965,242	7186617,63
Y	-49,2504	25,43914268	40,94	-1,271	3	40	675953,821	7186618,77
Y	-49,2505	23,03401248	37,069	-3,871	3	40	675943,409	7186621,35
Y	-49,2506	21,3412151	34,346	-2,723	3	40	675933,883	7186623,71
Y	-49,2507	19,5402444	31,446	-2,9	3	40	675925,029	7186624,95
Y	-49,2508	15,95671548	25,68	-5,766	3	40	675917,529	7186625,84
Y	-49,2508	10,71491258	17,244	-8,436	3	40	675912,105	7186626,47
Y	-49,2508	4,57089816	7,356	-9,888	3	40	675909,476	7186626,8
Y	-49,2509	1,07828086	1,736	-5,62	3	40	675908,606	7186626,92
Y	-49,2509	0,05523744	0,089	-1,647	3	40	675908,443	7186627,22
Y	-49,2509	0,1783709	0,287	0,198	3	40	675908,494	7186627,33
Y	-49,2509	0,13579204	0,218	-0,069	3	40	675908,396	7186627,51
Y	-49,2509	0,00805546	0,013	-0,205	3	40	675908,23	7186627,62
Y	-49,2509	0,08170538	0,132	-0,169	3	40	675907,95	7186628,03
Y	-49,2509	0,18757714	0,301	0,288	3	40	675908,115	7186627,83
Y	-49,2509	0,05868978	0,094	-0,038	3	40	675907,8	7186628,07
Y	-49,2509	0,1323397	0,213	0,119	3	40	675907,7	7186628,15
Y	-49,2509	0,05868978	0,095	-0,118	3	40	675907,583	7186628,22
Y	-49,2509	0,15420452	0,247	0,152	3	40	675907,566	7186628,21
Y	-49,2509	0,05063432	0,081	-0,166	3	40	675907,516	7186628,21
Y	-49,2509	0,0172617	0,028	-0,053	3	40	675907,365	7186628,19
Y	-49,2509	0,07940382	0,128	0,1	3	40	675907,213	7186628,12
Y	-49,2509	0,06789602	0,11	-0,018	3	40	675907,062	7186628,12
Y	-49,2509	0,0632929	0,102	-0,008	3	40	675906,963	7186628,23
Y	-49,2509	0,0287695	0,047	-0,055	3	40	675906,861	7186628,14
Y	-49,2509	0,0172617	0,028	-0,016	3	40	675906,744	7186628,14
Y	-49,2509	0,02761872	0,044	-0,003	3	40	675906,811	7186628,12

De forma análoga, tal procedimento foi aplicado para as estações meteorológicas.

Posteriormente, definiu-se a estação mais próxima do condutor segundo a segundo. Para tal, utilizou-se a função *cdist*, da biblioteca “*scipy*” para calcular a distância euclidiana entre as coordenadas UTM de cada estação e as coordenadas UTM registradas pelo veículo ao longo do tempo.

A cada segundo, a menor distância entre o veículo e as estações foi calculada e, em uma nova coluna do “*DataFrame*”, denominada “Estação Mais Próxima” foi registrado o nome da estação mais próxima, conforme mostra a Tabela 6.4. Essa abordagem permitiu uma identificação dinâmica e precisa da estação pluviométrica mais próxima do veículo em tempo real, facilitando a correlação entre as condições climáticas e o comportamento dos motoristas durante o percurso.

Tabela 6.4. Identificação da estação mais próxima do condutor

DRIVE	LONG	SPD_MPH	SPD_KMH	ACEL_MS2	LIMITE	UTM_E	UTM_N	ESTACAO
Y	-49,2503	26,22857776	42,211	0,006	40	675965,242	7186617,63	Vista Alegre
Y	-49,2504	25,43914268	40,94	-1,271	40	675953,821	7186618,77	Vista Alegre
Y	-49,2505	23,03401248	37,069	-3,871	40	675943,409	7186621,35	Vista Alegre
Y	-49,2506	21,3412151	34,346	-2,723	40	675933,883	7186623,71	Vista Alegre
Y	-49,2507	19,5402444	31,446	-2,9	40	675925,029	7186624,95	Vista Alegre
Y	-49,2508	15,95671548	25,68	-5,766	40	675917,529	7186625,84	Vista Alegre
Y	-49,2508	10,71491258	17,244	-8,436	40	675912,105	7186626,47	Vista Alegre
Y	-49,2508	4,57089816	7,356	-9,888	40	675909,476	7186626,8	Vista Alegre
Y	-49,2509	1,07828086	1,736	-5,62	40	675908,606	7186626,92	Vista Alegre
Y	-49,2509	0,05523744	0,089	-1,647	40	675908,443	7186627,22	Vista Alegre
Y	-49,2509	0,1783709	0,287	0,198	40	675908,494	7186627,33	Vista Alegre
Y	-49,2509	0,13579204	0,218	-0,069	40	675908,396	7186627,51	Vista Alegre
Y	-49,2509	0,00805546	0,013	-0,205	40	675908,23	7186627,62	Vista Alegre
Y	-49,2509	0,08170538	0,132	-0,169	40	675907,95	7186628,03	Vista Alegre
Y	-49,2509	0,18757714	0,301	0,288	40	675908,115	7186627,83	Vista Alegre
Y	-49,2509	0,05868978	0,094	-0,038	40	675907,8	7186628,07	Vista Alegre
Y	-49,2509	0,1323397	0,213	0,119	40	675907,7	7186628,15	Vista Alegre
Y	-49,2509	0,05868978	0,095	-0,118	40	675907,583	7186628,22	Vista Alegre
Y	-49,2509	0,15420452	0,247	0,152	40	675907,566	7186628,21	Vista Alegre
Y	-49,2509	0,05063432	0,081	-0,166	40	675907,516	7186628,21	Vista Alegre
Y	-49,2509	0,0172617	0,028	-0,053	40	675907,365	7186628,19	Vista Alegre
Y	-49,2509	0,07940382	0,128	0,1	40	675907,213	7186628,12	Vista Alegre
Y	-49,2509	0,06789602	0,11	-0,018	40	675907,062	7186628,12	Vista Alegre
Y	-49,2509	0,0632929	0,102	-0,008	40	675906,963	7186628,23	Vista Alegre
Y	-49,2509	0,0287695	0,047	-0,055	40	675906,861	7186628,14	Vista Alegre
Y	-49,2509	0,0172617	0,028	-0,016	40	675906,744	7186628,14	Vista Alegre

6.4 Combinação dos dados meteorológicos e de condução

Devido à diferença na unidade de registro dos dados de precipitação (de 10 em 10 min durante eventos de chuva ou 1 hora, em períodos sem precipitação) e de condução (segundo a segundo), assumiu-se que a precipitação em cada segundo equivale ao valor registrado pela estação meteorológica localizada mais próxima do veículo no instante da medição.

Para combinar as informações temporais das estações meteorológicas e do condutor, utilizou-se dados disponíveis em duas planilhas:

- Planilha 1 (Informações dos condutores): Continha as colunas 'Estação Mais Próxima', 'Data' e 'Hora' (s), representando a localização e o tempo de cada registro dos veículos.
- Planilha 2 (Dados de Precipitação): Incluía as colunas 'Estação', 'Data', 'Hora', e 'Quantidade de Precipitação (mm)', com o volume de chuva nas estações pluviométricas ao longo do tempo (10 em 10min ou de hora em hora).

A integração destes registros foi realizada utilizando a função “*pd.merge*” da biblioteca “*pandas*”, que permite combinar dois conjuntos de dados (*DataFrames*) com base em uma chave comum, neste caso a coluna “Estação”. Essa junção possibilitou que cada registro de viagem fosse associado ao dado de precipitação mais próximo da respectiva estação meteorológica. Esse processo resultou em um *DataFrames* contendo uma coluna denominada "quantidade mm" com o volume de precipitação registrado pelo CEMADEN da estação mais próxima do condutor a cada segundo de sua viagem. A Tabela 6.5 apresenta uma amostra da combinação dos dados meteorológicos e de condução.

Tabela 6.5. Combinação dos dados meteorológicos e de condução

DRIVE ▾	LONG ▾	SPD_MPH ▾	SPD_KMH ▾	ACEL_MS2 ▾	UTM_E ▾	UTM_N ▾	ESTACAO ▾	QUANTIDADE_MM ▾
Y	-49,2503	26,22857776	42,211	0,006	675965,242	7186617,626	Vista Alegre	2,4
Y	-49,2504	25,43914268	40,94	-1,271	675953,821	7186618,773	Vista Alegre	2,4
Y	-49,2505	23,03401248	37,069	-3,871	675943,409	7186621,347	Vista Alegre	2,4
Y	-49,2506	21,3412151	34,346	-2,723	675933,883	7186623,706	Vista Alegre	2,4
Y	-49,2507	19,5402444	31,446	-2,9	675925,029	7186624,949	Vista Alegre	2,4
Y	-49,2508	15,95671548	25,68	-5,766	675917,529	7186625,841	Vista Alegre	2,4
Y	-49,2508	10,71491258	17,244	-8,436	675912,105	7186626,466	Vista Alegre	2,4
Y	-49,2508	4,57089816	7,356	-9,888	675909,476	7186626,796	Vista Alegre	2,4
Y	-49,2509	1,07828086	1,736	-5,62	675908,606	7186626,918	Vista Alegre	2,4
Y	-49,2509	0,05523744	0,089	-1,647	675908,443	7186627,216	Vista Alegre	2,4
Y	-49,2509	0,1783709	0,287	0,198	675908,494	7186627,326	Vista Alegre	2,4
Y	-49,2509	0,13579204	0,218	-0,069	675908,396	7186627,511	Vista Alegre	2,4
Y	-49,2509	0,00805546	0,013	-0,205	675908,23	7186627,624	Vista Alegre	2,4
Y	-49,2509	0,08170538	0,132	-0,169	675907,95	7186628,035	Vista Alegre	2,4
Y	-49,2509	0,18757714	0,301	0,288	675908,115	7186627,83	Vista Alegre	2,4
Y	-49,2509	0,05868978	0,094	-0,038	675907,8	7186628,073	Vista Alegre	2,4
Y	-49,2509	0,1323397	0,213	0,119	675907,7	7186628,149	Vista Alegre	2,4
Y	-49,2509	0,05868978	0,095	-0,118	675907,583	7186628,224	Vista Alegre	2,4
Y	-49,2509	0,15420452	0,247	0,152	675907,566	7186628,206	Vista Alegre	2,4
Y	-49,2509	0,05063432	0,081	-0,166	675907,516	7186628,206	Vista Alegre	2,4
Y	-49,2509	0,0172617	0,028	-0,053	675907,365	7186628,19	Vista Alegre	2,4
Y	-49,2509	0,07940382	0,128	0,1	675907,213	7186628,118	Vista Alegre	2,4
Y	-49,2509	0,06789602	0,11	-0,018	675907,062	7186628,12	Vista Alegre	2,4
Y	-49,2509	0,0632929	0,102	-0,008	675906,963	7186628,233	Vista Alegre	2,4
Y	-49,2509	0,0287695	0,047	-0,055	675906,861	7186628,141	Vista Alegre	2,4
Y	-49,2509	0,0172617	0,028	-0,016	675906,744	7186628,142	Vista Alegre	2,4
Y	-49,2509	0,02761872	0,044	-0,003	675906,811	7186628,124	Vista Alegre	2,4

6.5 Classificação das condições meteorológicas:

Esta pesquisa considerou duas categorias para avaliar o comportamento do condutor, sendo elas:

- sem chuva: inclui todos os registros onde a precipitação foi igual a 0 mm.
- com chuva: abrange todos os registros com qualquer quantidade de precipitação superior a 0 mm.

Assim, a partir do registro da coluna "quantidade mm" no *DataFrame*, classificou-se cada segundo de viagem do condutor em com ou sem chuva e os resultados foram inseridos em uma nova coluna denominada “condição”, conforme mostra Tabela 6.6.

Tabela 6.6. Classificação das condições meteorológicas

DRIV	LONG	SPD_MPH	SPD_KMH	ACEL_MS	UTM_E	UTM_N	ESTACAO	QUANTIDADE_N	CONDICAO_CHU
Y	-49,2503	26,22857776	42,211	0,006	675965,242	7186617,626	Vista Alegre	2,4	Chuva
Y	-49,2504	25,43914268	40,94	-1,271	675953,821	7186618,773	Vista Alegre	2,4	Chuva
Y	-49,2505	23,03401248	37,069	-3,871	675943,409	7186621,347	Vista Alegre	2,4	Chuva
Y	-49,2506	21,3412151	34,346	-2,723	675933,883	7186623,706	Vista Alegre	2,4	Chuva
Y	-49,2507	19,5402444	31,446	-2,9	675925,029	7186624,949	Vista Alegre	2,4	Chuva
Y	-49,2508	15,95671548	25,68	-5,766	675917,529	7186625,841	Vista Alegre	2,4	Chuva
Y	-49,2508	10,71491258	17,244	-8,436	675912,105	7186626,466	Vista Alegre	2,4	Chuva
Y	-49,2508	4,57089816	7,356	-9,888	675909,476	7186626,796	Vista Alegre	2,4	Chuva
Y	-49,2509	1,07828086	1,736	-5,62	675908,606	7186626,918	Vista Alegre	2,4	Chuva
Y	-49,2509	0,05523744	0,089	-1,647	675908,443	7186627,216	Vista Alegre	2,4	Chuva
Y	-49,2509	0,1783709	0,287	0,198	675908,494	7186627,326	Vista Alegre	2,4	Chuva
Y	-49,2509	0,13579204	0,218	-0,069	675908,396	7186627,511	Vista Alegre	2,4	Chuva
Y	-49,2509	0,00805546	0,013	-0,205	675908,23	7186627,624	Vista Alegre	2,4	Chuva
Y	-49,2509	0,08170538	0,132	-0,169	675907,95	7186628,035	Vista Alegre	2,4	Chuva
Y	-49,2509	0,18757714	0,301	0,288	675908,115	7186627,83	Vista Alegre	2,4	Chuva
Y	-49,2509	0,05868978	0,094	-0,038	675907,8	7186628,073	Vista Alegre	2,4	Chuva
Y	-49,2509	0,1323397	0,213	0,119	675907,7	7186628,149	Vista Alegre	2,4	Chuva
Y	-49,2509	0,05868978	0,095	-0,118	675907,583	7186628,224	Vista Alegre	2,4	Chuva
Y	-49,2509	0,15420452	0,247	0,152	675907,566	7186628,206	Vista Alegre	2,4	Chuva
Y	-49,2509	0,05063432	0,081	-0,166	675907,516	7186628,206	Vista Alegre	2,4	Chuva
Y	-49,2509	0,0172617	0,028	-0,053	675907,365	7186628,19	Vista Alegre	2,4	Chuva
Y	-49,2509	0,07940382	0,128	0,1	675907,213	7186628,118	Vista Alegre	2,4	Chuva
Y	-49,2509	0,06789602	0,11	-0,018	675907,062	7186628,12	Vista Alegre	2,4	Chuva
Y	-49,2509	0,0632929	0,102	-0,008	675906,963	7186628,233	Vista Alegre	2,4	Chuva
Y	-49,2509	0,0287695	0,047	-0,055	675906,861	7186628,141	Vista Alegre	2,4	Chuva
Y	-49,2509	0,0172617	0,028	-0,016	675906,744	7186628,142	Vista Alegre	2,4	Chuva
Y	-49,2509	0,02761872	0,044	-0,003	675906,811	7186628,124	Vista Alegre	2,4	Chuva
Y	-49,2509	0,0287695	0,046	0,018	675906,66	7186628,126	Vista Alegre	2,4	Chuva

6.6 Divisão das viagens com base nas mudanças climáticas

A análise da coluna “condição” no *DataFrame* permitiu identificar o momento que ocorreu a transição de uma área "sem chuva" para uma área "com chuva", ou vice-versa. Quando o veículo cruzou essa fronteira climática, a viagem original foi segmentada automaticamente, resultando em uma nova viagem. Assim, a partir do momento em que as condições meteorológicas sofreram alteração, iniciou-se a contabilização de uma nova viagem, permitindo que as métricas de desempenho do veículo, como velocidade, aceleração e

frenagem, fossem analisadas de maneira isolada para cada fase da viagem: antes da chuva e durante a chuva. Essa divisão das viagens foi operacionalizada no Excel por meio da seguinte fórmula:

=CONCATENAR([Coluna1];[Coluna2];".";SE([ColunaChuva]="Semchuva";1;SE([ColunaChuva]="Com chuva"; 2; "")))

Esta equação foi aplicada para concatenar os identificadores do condutor e da viagem, adicionando um sufixo numérico que representa as condições climáticas: o valor 1 para as viagens realizadas em condições "sem chuva" e o valor 2 para viagens realizadas em condições "com chuva". Esse procedimento gerou um código para cada viagem, permitindo que os dados fossem segmentados e analisados separadamente, conforme as condições climáticas encontradas ao longo da rota. A Tabela 6.7 apresenta uma amostra desta etapa.

Tabela 6.7. Subdivisão das viagens conforme mudança na condição climática.

DRIVER	LONG	SPD_MPH	SPD_KMH	ACEL_MS2	UTM_E	UTM_N	ESTACAO	QUANTIDADE_MM	CONDICAO_CHUVA	ID
O	-49,2943	1,26240566	2,032	0	671482,229	7181968,421	Vista Alegre	0	Sem chuva	O01
O	-49,2942	0,98046456	1,577	-0,455	671483,247	7181970,624	Vista Alegre	0	Sem chuva	O01
O	-49,2942	0,16571232	0,267	-1,31	671484,374	7181971,053	Vista Alegre	0	Sem chuva	O01
O	-49,2942	0,41197924	0,663	-0,244	671486,094	7181971,806	Vista Alegre	0	Sem chuva	O01
O	-49,2942	0,5638822	0,907	0,64	671485,299	7181971,225	Vista Alegre	0	Sem chuva	O01
O	-49,2942	0,09321318	0,15	-0,513	671486,15	7181972,304	Vista Alegre	0	Sem chuva	O01
O	-49,2942	0,36709882	0,59	0,44	671486,615	7181973,221	Vista Alegre	0	Sem chuva	O01
O	-49,2942	0,67665864	1,089	0,107	671488,023	7181973,277	Vista Alegre	0	Sem chuva	O01
O	-49,2942	0,6099134	0,982	0,392	671487,524	7181973,523	Vista Alegre	0	Sem chuva	O01
O	-49,2942	0,89990996	1,448	0,359	671488,849	7181973,58	Vista Alegre	0	Sem chuva	O01
O	-49,2942	1,51557726	2,44	0,992	671490,13	7181974,117	Vista Alegre	0	Sem chuva	O01
Y	-49,2596	0,13349048	0,216	0	674861,974	7173860,364	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,00805546	0,012	-0,204	674859,46	7173862,76	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,115078	0,186	0,174	674859,723	7173862,498	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,03912652	0,064	-0,122	674860,286	7173861,956	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,0345234	0,055	-0,009	674860,269	7173861,956	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,20368806	0,327	0,272	674860,551	7173861,675	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,09896708	0,16	-0,167	674860,338	7173862,047	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,10011786	0,162	0,002	674860,174	7173862,363	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,06099134	0,099	-0,063	674859,963	7173862,864	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,0920624	0,148	0,049	674859,95	7173863,141	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,0460312	0,075	-0,073	674859,953	7173863,345	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,08285612	0,132	0,057	674859,939	7173863,584	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,07940382	0,128	-0,004	674859,941	7173863,769	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,05523744	0,088	-0,04	674860,027	7173863,86	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,0287695	0,045	-0,043	674860,06	7173863,897	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,02416638	0,04	-0,005	674860,111	7173863,897	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,03567418	0,058	0,018	674860,16	7173863,858	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,05063432	0,082	0,024	674860,11	7173863,822	Umbará	0	Sem chuva	Y01
Y	-49,2596	0,01611092	0,025	-0,057	674860,059	7173863,823	Umbará	0	Sem chuva	Y01

6.7 Classificação das subviagens em Diurno ou Noturno e Pico ou Entre Picos

A categorização dos períodos em diurno ou noturno foi realizada com base nos horários de nascer e pôr do sol para a cidade de Curitiba/ PR nos dias da pesquisa, obtidas no site: <https://www.sunrise-and-sunset.com/pt/sun/brasil/curitiba/>. Esses dados foram organizados em

uma tabela, e posteriormente integrados ao “*DataFrame*” por meio de um script desenvolvido em “*Python*”. Esse script automatizou o processo de cruzamento entre os horários de início de cada viagem e os respectivos horários de nascer e pôr do sol, permitindo a categorização de cada viagem em "diurno" ou "noturno".

Para analisar o comportamento dos motoristas em relação aos horários de pico (períodos de maior volume de tráfego) e entre picos (períodos com menor fluxo de veículos) adotou-se como horários de pico 07:00 e 08:00 e entre 18:00 e 19:00. Os demais horários foram tratados como "entre picos", de modo a facilitar a segmentação das viagens nesses períodos específicos.

A Tabela 6.8 apresenta a amostra da planilha resultante da classificação das subviagens em com chuva ou sem chuva, diurno ou noturno e em horário de pico ou entre picos. Assim, cada linha da tabela reflete um segmento de viagem, categorizado de acordo com as condições de luminosidade (diurno ou noturno) e os períodos de tráfego (pico ou entre picos).

Tabela 6.8 Classificação das subviagens com e sem chuva, diurno e noturno e Pico e entre picos

Condição_Chuva	%V1	%V2	%V3	%A1	%A2	%F1	%F2	Periodo	Horario_Pic
Sem chuva	100,0	0,0	0,0	40,8	0,0	59,2	0,0	Noturno	Pico
Sem chuva	100,0	0,0	0,0	45,5	9,1	36,4	9,1	Noturno	Entre Picos
Sem chuva	100,0	0,0	0,0	50,0	0,0	50,0	0,0	Diurno	Pico
Sem chuva	100,0	0,0	0,0	49,2	2,1	45,5	3,2	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	41,8	0,0	58,2	0,0	Diurno	Pico
Sem chuva	100,0	0,0	0,0	50,0	2,3	45,5	2,3	Noturno	Pico
Sem chuva	100,0	0,0	0,0	54,8	0,0	37,5	7,7	Diurno	Pico
Sem chuva	75,4	16,3	8,3	48,3	5,0	37,9	8,8	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	48,4	0,0	51,6	0,0	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	32,4	0,0	64,9	2,7	Noturno	Entre Picos
Sem chuva	76,9	17,9	5,1	43,6	2,6	46,2	7,7	Diurno	Pico
Chuva	100,0	0,0	0,0	51,2	0,0	48,8	0,0	Diurno	Entre Picos
Chuva	100,0	0,0	0,0	41,7	0,0	58,3	0,0	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	51,3	0,0	48,7	0,0	Noturno	Entre Picos
Sem chuva	100,0	0,0	0,0	53,0	0,0	47,0	0,0	Noturno	Entre Picos
Sem chuva	100,0	0,0	0,0	47,5	0,0	52,5	0,0	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	53,3	0,0	46,7	0,0	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	50,4	0,0	49,6	0,0	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	50,5	0,0	49,5	0,0	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	49,0	0,0	51,0	0,0	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	56,0	0,0	44,0	0,0	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	46,6	0,0	53,4	0,0	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	52,4	0,0	47,6	0,0	Diurno	Pico
Sem chuva	100,0	0,0	0,0	47,3	0,0	52,7	0,0	Diurno	Entre Picos
Sem chuva	100,0	0,0	0,0	13,6	36,4	20,5	29,5	Diurno	Entre Picos
Sem chuva	91,9	8,1	0,0	54,4	3,0	41,9	0,7	Diurno	Entre Picos
Sem chuva	89,2	7,9	2,9	45,3	1,5	52,7	0,5	Diurno	Pico
Sem chuva	100,0	0,0	0,0	52,1	1,0	44,7	2,3	Diurno	Pico
Sem chuva	95,9	4,0	0,1	47,5	1,2	50,7	0,5	Diurno	Pico
Sem chuva	100	0	0	50,3	2,1	46,5	1,1	Diurno	Pico

6.8. Hipóteses 1, 2 e 3:

A: Cálculo das porcentagens de tempo de permanência em faixas de velocidade, aceleração e frenagem

Após a divisão das viagens em subviagens de acordo com a condição climática, foi implementado um código no *Python* para calcular as porcentagens de tempo que os veículos permanecem em cada faixas de comportamento avaliada. O cálculo foi baseado nas informações presentes na planilha dos condutores, especialmente as colunas: SPD_MPH (velocidade do veículo em milhas por hora), SPD_KMH: (velocidade do veículo em quilômetros por hora), ACEL_MS2 (aceleração do veículo em metros por segundo ao quadrado) e LIMITE_VEL (limite de velocidade da via em que o veículo estava trafegando).

Os comportamentos dos condutores foram avaliados conforme faixas de velocidade (V1, V2 e V3), aceleração (A1 e A2) e frenagem (F1 e F2) apresentados no passo 4.7 da metodologia. Assim, para cada subviagem monitorada foram obtidos sete dados: V1, V2, V3, A1, A2, F1 e F2 em porcentagem do tempo total da viagem, gerando amostras que representam os diversos parâmetros investigados. A soma destes percentuais em cada categoria de velocidade (V1, V2 e V3) é igual a 100%. No que se refere à aceleração e frenagem (A1, A2, F1 e F2), a soma de suas porcentagens também é igual a 100%.

Estes resultados foram integrados ao “*DataFrame*” principal, possibilitando uma análise completa dos segmentos de viagem com base nas condições meteorológicas e comportamentais. O “*DataFrame*” final foi exportado para um arquivo Excel.

A Tabela 6.9 apresenta uma amostra da planilha gerada a partir da análise dos segmentos de viagem, categorizados com base nas condições climáticas. Cada linha da planilha corresponde a um segmento de viagem e contém as porcentagens de tempo que o veículo permaneceu em diferentes faixas de velocidade, aceleração e frenagem, além da duração total de cada subviagem, em minutos.

Tabela 6.9 Tempo de permanência em cada faixa de Velocidade, Aceleração e Frenagem (%)

Condição Chuva	Tempo Viagem	%V1	%V2	%V3	%A1	%A2	%F1	%F2
Sem chuva	00:02:04	100,0	0,0	0,0	40,8	0,0	59,2	0,0
Sem chuva	00:13:58	100,0	0,0	0,0	45,5	9,1	36,4	9,1
Sem chuva	00:00:37	100,0	0,0	0,0	50,0	0,0	50,0	0,0
Sem chuva	00:03:08	100,0	0,0	0,0	49,2	2,1	45,5	3,2
Sem chuva	00:01:18	100,0	0,0	0,0	41,8	0,0	58,2	0,0
Sem chuva	00:00:43	100,0	0,0	0,0	50,0	2,3	45,5	2,3
Sem chuva	00:01:47	100,0	0,0	0,0	54,8	0,0	37,5	7,7
Sem chuva	00:04:33	75,4	16,3	8,3	48,3	5,0	37,9	8,8
Sem chuva	00:03:45	100,0	0,0	0,0	48,4	0,0	51,6	0,0
Sem chuva	00:00:36	100,0	0,0	0,0	32,4	0,0	64,9	2,7
Sem chuva	00:00:38	76,9	17,9	5,1	43,6	2,6	46,2	7,7
Chuva	00:02:50	100,0	0,0	0,0	51,2	0,0	48,8	0,0
Chuva	00:44:59	100,0	0,0	0,0	41,7	0,0	58,3	0,0
Sem chuva	00:01:17	100,0	0,0	0,0	51,3	0,0	48,7	0,0
Sem chuva	00:05:14	100,0	0,0	0,0	53,0	0,0	47,0	0,0
Sem chuva	00:00:39	100,0	0,0	0,0	47,5	0,0	52,5	0,0
Sem chuva	00:06:18	100,0	0,0	0,0	53,3	0,0	46,7	0,0
Sem chuva	00:02:14	100,0	0,0	0,0	50,4	0,0	49,6	0,0
Sem chuva	00:01:44	100,0	0,0	0,0	50,5	0,0	49,5	0,0
Sem chuva	00:35:08	100,0	0,0	0,0	49,0	0,0	51,0	0,0
Sem chuva	00:01:39	100,0	0,0	0,0	56,0	0,0	44,0	0,0
Sem chuva	00:02:29	100,0	0,0	0,0	46,6	0,0	53,4	0,0
Sem chuva	00:02:26	100,0	0,0	0,0	52,4	0,0	47,6	0,0
Sem chuva	00:03:39	100,0	0,0	0,0	47,3	0,0	52,7	0,0
Sem chuva	00:36:38	100,0	0,0	0,0	13,6	36,4	20,5	29,5
Sem chuva	00:06:08	91,9	8,1	0,0	54,4	3,0	41,9	0,7
Sem chuva	00:34:48	89,2	7,9	2,9	45,3	1,5	52,7	0,5
Sem chuva	00:06:05	100,0	0,0	0,0	52,1	1,0	44,7	2,3
Sem chuva	00:27:51	95,9	4,0	0,1	47,5	1,2	50,7	0,5
Sem chuva	00:09:50	100	0	0	50,3	2,1	46,5	1,1

Salienta-se que viagens com duração inferior a 30 segundos foram desconsideradas.

B: Identificação da quantidade de amostras por categoria investigada

A partir da Tabela contendo a classificação das subviagens em com ou sem chuva, diurno ou noturno e Pico ou entre picos, identificou-se 543 amostras, as quais foram categorizadas em: (i) com chuva e sem chuva, (ii) diurno ou noturno com chuva; e (iii) Pico e entre picos com chuva.

Na categoria (i), sob condições de tempo seco, ocorreram 512 subviagens (94,29% do total de subviagens), representando aproximadamente 308,59 horas de condução (94,43% do tempo total das viagens). Por outro lado, sob condições de chuva, ocorreram 31 viagens (5,71% do total), totalizando aproximadamente 18,19 horas de condução (5,57% do tempo total das viagens).

Na categoria (ii), 21 subviagens (amostras) com chuva foram realizadas durante o dia (67,74% das viagens com chuva), acumulando 13,44 horas de condução (73,91% do tempo de condução com chuva). No período noturno, houve o registro de 10 subviagens com chuva

(32,26% das viagens com chuva), totalizando 4,74 horas de condução (26,09% do tempo de condução com chuva).

Na última categoria, (iii), 25 subviagens ocorreram durante entre picos com chuva (80,65% das viagens com chuva), somando 15,88 horas de condução (87,35% do tempo de condução com chuva). Durante os horários de pico com chuva, 6 viagens foram realizadas (19,35% das subviagens com chuva), com um total de 2,31 horas de condução (12,65% do tempo de condução com chuva).

C: Resultados, Análises e Discussões

As três primeiras hipóteses foram analisadas, considerando duas abordagens distintas: (i) sem a aplicação do *bootstrap* na amostra original; e (ii) com a aplicação do *bootstrap* na amostra original. Como mencionado anteriormente, essas abordagens partem do pressuposto de que o comportamento dos condutores é homogêneo ao dirigir, ou seja, não levam em consideração aspectos individuais, como experiência, estilo de direção, preferências pessoais ou outras características que possam influenciar a forma como cada motorista conduz o veículo. Todos os testes estatísticos utilizaram $\alpha = 0,05$.

A seguir, são apresentados os resultados referentes à Hipótese 1, que investiga:

Hipótese 1: A precipitação afeta a percentagem de tempo de permanência do condutor em cada faixa de velocidade, aceleração e frenagem investigada.

Esta hipótese analisa o comportamento dos condutores quanto ao percentual de tempo de permanência em diferentes faixas de velocidade, acelerações e frenagens, considerando o impacto das condições climáticas (com chuva e sem chuva). A análise foi dividida em três categorias de velocidade (V1, V2 e V3) além das variações de acelerações (A1 e A2), e frenagens (F1 e F2), em ambas as condições meteorológicas.


A Tabela 6.10 apresenta as estatísticas descritivas referentes à porcentagem de tempo de permanência dos condutores em cada faixa de velocidade, aceleração e frenagem, comparando as viagens realizadas em condições com e sem precipitação. São mostrados, para cada variável, os valores de média, mediana, desvio padrão, primeiro quartil (Q1), terceiro quartil (Q3) e intervalo interquartil (IQR), sem aplicação de técnicas de reamostragem (*bootstrap*), tomando-se por base a amostra original.

Tabela 6.10 Estatísticas descritivas: % V, A, F e IQR (sem chuva vs chuva)

Categorias	Amostras (subviagens)	Condições Meteorológicas	Média (%)	Mediana (%)	Desvio Padrão (%)	Q1	Q3	IQR
V1	512	Sem chuva	95,9	98,09	7,53	94,86	100	5,14
	31	Com chuva	95,9	97,56	4,42	94,16	100	5,84
V2	512	Sem chuva	2,81	1,51	4,07	0	3,87	3,87
	31	Com chuva	3,11	1,69	3,58	0	5,14	5,14
V3	512	Sem chuva	1,32	0	5,61	0	0,75	0,75
	31	Com chuva	0,946	0,5	1,4	0	1,40	1,40
A1	512	Sem chuva	45,1	47,7	17,7	35,11	53,03	17,92
	31	Com chuva	36,3	36,1	20,2	29,44	51,17	21,73
A2	512	Sem chuva	6,02	1,70	8,60	0,17	10,80	10,63
	31	Com chuva	9,07	1,65	11,0	0,02	17,11	17,09
F1	512	Sem chuva	36,5	39,6	13,08	29,63	46,57	16,94
	31	Com chuva	30,4	32,3	17,3	24,22	44,02	19,80
F2	512	Sem chuva	6,28	2,69	7,75	0,50	10,48	9,99
	31	Com chuva	8,08	2,67	8,94	0,00	17,15	17,15

A fim de complementar as estatísticas descritivas apresentadas na Tabela 6.10, foram elaborados *boxplots* (Figura 6.2), que permitem visualizar a distribuição das variáveis e analisar a dispersão via intervalo interquartil (IQR), já discutido numericamente. Além disso, os *boxplots* mostram a presença de valores atípicos, contribuindo para a caracterização do comportamento dos condutores sob diferentes contextos climáticos.

Figura 6.2 % de tempo de permanência em faixas de V, A e F (sem chuva e com chuva)



A Figura 6.2 mostra que a variável V1 (percentual do tempo em que os condutores trafegaram com velocidade mais de 10% inferior ao limite máximo permitido na via) apresentou

intervalos interquartis (IQR) próximos entre as condições sem chuva (5,14%) e com chuva (5,84%). Em ambas as situações, a caixa do *boxplot* manteve-se compacta e posicionada na parte superior da escala, indicando que uma parcela dos condutores manteve a condução em velocidades reduzidas. Todavia, o alargamento do IQR sob chuva, embora sutil, pode sinalizar um comportamento heterogêneo mesmo dentro da faixa. Essa interpretação é compatível com o estudo de Matsuoka (2024), que relaciona o alargamento do IQR sob chuva à intensificação da heterogeneidade nas séries de precipitação.

V2 (percentagem de tempo com velocidade entre 10% menor e 10% maior que a velocidade máxima permitida na via) apresentou aumento no intervalo interquartil entre as condições sem chuva e com chuva, passando de 3,87% para 5,14%. Em ambas as situações, a caixa do *boxplot* se manteve próxima à base da escala, indicando que a maioria dos condutores passou pouco tempo dentro dessa faixa. A maior amplitude sob chuva sugere aumento da variabilidade no comportamento, possivelmente refletindo estratégias distintas frente à condição adversa. Esse resultado é coerente com Gonzalez *et al.* (2007), que ressaltaram que fatores como as condições meteorológicas alteram os padrões de velocidade e ampliam a variabilidade do comportamento dos condutores.

A variável V3 (percentual de tempo com velocidade superior a 10% do limite permitido) apresentou caixa estreita em ambas as condições, concentrada próxima ao valor mínimo da escala. O intervalo interquartil aumentou de 0,75% para 1,40% entre as condições sem chuva e com chuva. Apesar da baixa frequência absoluta, esse aumento indicou a ocorrência de episódios pontuais de excesso de velocidade mesmo em ambiente de menor aderência. A presença de uma cauda superior mais alongada sob chuva, evidenciada na Figura 6.2, reforçou essa interpretação, apontando para maior variabilidade no controle de velocidade. Resultados semelhantes foram encontrados por Wang *et al.* (2021), que identificaram que a precipitação não elimina episódios de excesso de velocidade, mas provoca maior heterogeneidade no comportamento dos condutores, ampliando a distância entre aqueles que reduzem a velocidade e aqueles que persistem em trafegar acima do limite, o que se reflete em maior dispersão estatística das velocidades observadas.

A variável A1 (percentual do tempo com acelerações normais, $0 \leq a \leq 1,5 \text{ m/s}^2$) apresentou, conforme Figura 6.2, expansão do intervalo interquartil, que aumentou de 17,92% para 21,73% da condição seca para a chuvosa, refletindo a diversidade no uso desse tipo de aceleração entre os condutores. Esse comportamento corrobora com estudo realizado por Rakha, Van Aerde e Ahn (2009), que verificaram que a chuva amplia a variabilidade no padrão

de aceleração, justamente porque cada condutor reage de modo distinto às demandas adicionais de tração e segurança impostas pela via molhada

Comportamento similar foi encontrado em relação a variável A2 (tempo com acelerações superiores a $1,5 \text{ m/s}^2$) que apresentou aumento visível na dispersão sob chuva, com o intervalo interquartil aumentando de 10,63% para 17,09% sob condição chuvosa, o que indica maior variabilidade no tempo em que o grupo de condutores realizaram acelerações abruptas (A2). Esse aumento de dispersão revela um comportamento menos uniforme. Tal heterogeneidade pode estar associada a diferenças na percepção de risco, nível de experiência, estilo de condução ou dinâmica do tráfego. A presença de uma cauda superior mais alongada mostra que parte do grupo de condutores recorreram com maior frequência a acelerações abruptas, contrariando a expectativa de moderação típica em condições adversas.

A variável F1 (percentual de tempo com frenagens normais, entre $-1,5 \text{ m/s}^2$ e 0) apresentou aumento no intervalo interquartil, passando de 16,94% em condição seca para 19,80% sob chuva. Embora ambas as caixas do boxplot apresentam que esse tipo de frenagem é amplamente utilizado, a maior dispersão sob chuva indica variabilidade mais acentuada na forma como os condutores modulam suas reduções de velocidade. Esse comportamento pode estar relacionado ao aumento da imprevisibilidade do tráfego em vias molhadas, que exige frenagens mais frequentes e ajustadas. Esse resultado é coerente com Budzyński *et al.* (2022), que verificaram que a chuva intensifica a heterogeneidade das respostas de frenagem normal, já que parte dos condutores opta por estratégias suaves e consistentes, enquanto outros recorrem a intervenções mais reativas para manter o controle do veículo.

Para a variável F2 (porcentagem de tempo com frenagens abruptas, a $< -1,5 \text{ m/s}^2$), o intervalo interquartil praticamente dobrou ao passar de 9,99% em condição seca para 17,15% sob chuva. Esse aumento na dispersão indica um comportamento mais heterogêneo entre os condutores diante de situações que exigem desacelerações intensas. O boxplot sob chuva apresenta uma caixa mais longa e cauda superior estendida, revelando que os motoristas mantêm condutas mais agressivas mesmo em ambiente de baixa aderência. Situações em que os condutores apresentaram respostas rápidas a estímulos viários como fortes frenagens ou correções de direção podem indicar baixa capacidade de antecipação, caracterizando um modo reativo de condução.

Resultados semelhantes foram identificados em estudos anteriores, como os de Ni *et al.* (2022), Elyoussoufi *et al.* (2023) e Billot *et al.* (2009), que associam esse aumento na

heterogeneidade comportamental à redução da visibilidade, à diminuição da aderência do pavimento e à elevação da complexidade perceptiva durante a condução em ambientes adversos. A análise gráfica aqui apresentada confirma que a aceleração abrupta é uma resposta particularmente sensível a tais condições.

Conforme fluxograma apresentado na Figura 5.4 e 5.5, calculou-se os testes de normalidade de *D'Agostino-Pearson* (tamanho amostral superior a 50 observações) ou de *Shapiro-Wilk* (amostra inferior a 50 observações) para cada faixa de velocidade, aceleração e frenagem nas condições de tempo límpido e chuvoso. Os resultados destes testes estão apresentados na Tabela 6.11, que mostra os *p-valores* para as amostras originais.

Tabela 6.11. Teste de Normalidade: D'Agostino-Pearson ou de Shapiro-Wilk (sem chuva vs com chuva)

Variável	Condição	p-valor amostra original
V1	Sem chuva	1,69e-137 ¹
	Com chuva	5,96e-04 ¹
V2	Sem chuva	8,67e-70 ¹
	Com chuva	8,51e-05 ¹
V3	Sem chuva	1,27e-204 ¹
	Com chuva	1,47e-06 ¹
A1	Sem Chuva	0,0274 ¹
	Com Chuva	0,0000 ¹
A2	Sem Chuva	0,0000 ¹
	Com Chuva	0,0000 ¹
F1	Sem Chuva	0,0297 ¹
	Com Chuva	0,0000 ¹
F2	Sem Chuva	0,0000 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Os testes de normalidade (*Shapiro-Wilk* ou *D'Agostino-Pearson*) indicaram *p-valores* inferiores a 0,05 para todas as variáveis analisadas. Em função da rejeição da normalidade para a amostra original, procedeu-se com a aplicação do teste de *Hodges-Lehmann*, para estimar os intervalos de confiança e suas amplitudes. Na situação em que foi utilizada a técnica de reamostragem *bootstrap* com 2.000 réplicas, o IC foi obtido por meio do método *BCA*.

A Tabela 6.12 apresenta os intervalos de confiança gerados por ambos os métodos, bem como suas respectivas amplitudes (A), calculadas com 95% de confiança a partir da diferença entre os limites superior e inferior para as variáveis V1, V2 e V3, A1 e A2 e F1 e F2, nas condições com e sem chuva.

Tabela 6.12. IC e A: amostras originais e com *bootstrap* para V, A e F (sem chuva vs com chuva)

Variável	Condição	IC Original (superior e inferior)	Amplitude (%)	IC <i>bootstrap</i> BCa	Amplitude (%)
----------	----------	-----------------------------------	---------------	-------------------------	---------------

				(Inferior; Superior)	
V1	Sem Chuva	83,33 ; 100,00	16,67	95,05 ; 96,42	1,38
	Com Chuva	88,76 ; 100,00	11,24	94,22 ; 97,31	3,09
V2	Sem Chuva	0,00 ; 10,80	10,80	2,49 ; 3,20	0,71
	Com Chuva	0,00 ; 9,10	9,10	2,02 ; 4,50	2,48
V3	Sem Chuva	0,00 ; 7,75	7,75	0,96 ; 2,06	1,10
	Com Chuva	0,00 ; 3,47	3,47	0,55 ; 1,52	0,98
A1	Sem Chuva	17,25 ; 68,37	51,12	46,63 ; 48,57	1,94
	Com Chuva	0,00 ; 62,59	62,59	31,86 ; 41,67	9,81
A2	Sem Chuva	0,00 ; 20,80	20,80	1,410 ; 1,920	0,51
	Com Chuva	0,00 ; 26,62	26,62	0,180 ; 14,87	14,69
F1	Sem Chuva	14,50 ; 51,33	36,83	37,40 ; 41,25	3,84
	Com Chuva	0,00 ; 51,59	51,59	25,68 ; 37,50	11,82
F2	Sem Chuva	0,00 ; 19,16	19,16	2,310 ; 3,210	0,90
	Com Chuva	0,00 ; 21,54	21,54	0,180 ; 13,03	12,85

A Tabela 6.12 mostra que os intervalos de confiança estimados pelo método *bootstrap* BCa apresentaram-se mais estreitos para todas as variáveis quando comparados com os obtidos pelo *Hodges-Lehmann*. Essa redução na amplitude dos intervalos indica maior precisão nas estimativas pontuais, sugerindo menor variabilidade amostral e maior robustez do método *bootstrap* BCa na avaliação das diferenças de comportamento entre as condições com e sem chuva.

Como os testes de normalidade, apresentados na Tabela 6.11, resultaram na rejeição da hipótese de distribuição normal, aplicou-se o teste não paramétrico de *Kruskal-Wallis*, conforme o fluxograma da Figura 5.4. A Tabela 6.13 apresenta os p-valores obtidos a partir da aplicação desse teste para a avaliação das faixas de velocidades tanto para as amostras originais quanto com reamostragem *bootstrap*.

Tabela 6.13 Teste não paramétrico de Kruskal-Wallis: velocidades (sem chuva vs com chuva)

Teste	p-valor (amostra original)	p-valor (amostra BCa)
Kruskal-Wallis	$p < 0,01^1$	$p < 0,01^1$

¹Diferença significativa; ²Não há diferença significativa.

Conforme indicado na Tabela 6.13, o teste de *Kruskal-Wallis* apresentou significância estatística com p-valores próximos de zero ($p < 0,01$), evidenciando diferenças no comportamento dos condutores entre condições com e sem chuva. O p-valor obtido pelo método *bootstrap* também apresentou resultado semelhante.

Dado que o referido teste apresenta a existência de diferenças sem especificar onde elas ocorrem, foi conduzido um teste *pós-hoc de Dunn*, conforme fluxograma apresentado na Figura 5.4. Esse teste permite realizar comparações múltiplas entre os grupos, identificando quais pares apresentam diferenças significativas. Os resultados destas comparações (resultantes do teste de Dunn) estão apresentados na Tabela 6.14.

Tabela 6.14 Teste Dunn – Amostra Original e com *bootstrap* (sem chuva vs com chuva)

Grupo 1	Grupo 2	Amostra original		Amostra- <i>bootstrap</i>	
		Z-score	p-valor (Holm)	Z-score	p-valor (Holm)
V1_chuva	V1_sem chuva	-0,2609	7,94e-01 ²	2,3267	9,99e-03 ¹
V2_chuva	V2_sem chuva	0,4631	1,00e+00 ²	10,207	1,84e-24 ¹
V3_chuva	V3_sem chuva	0,8154	1,00e+00 ²	-20,595	4,51e-94 ¹
V2_chuva	V3_chuva	1.3333	3.65e-01 ²	45.818	0.00e+00 ¹
V2_sem chuva	V3_sem chuva	6.4613	4.15e-10 ¹	27.099	2.02e-16 ¹

¹Diferença significativa; ²Não há diferença significativa.

A Tabela 6.14 mostra que a amostra original não apresentou diferença estatisticamente significativa ($p = 0,794$) ao comparar os grupos V1 com chuva e V1 sem chuva, sugerindo que o grupo de condutores, em velocidades reduzidas, mantém comportamento semelhante independentemente da presença de chuva. O valor de Z ($-0,26$) reforça a baixa magnitude da diferença observada, sem evidências de alteração no tempo de permanência na faixa. No entanto, a análise com reamostragem *bootstrap* revelou diferença estatisticamente significativa entre os grupos ($Z = 2,33$; $p = 9,99 \times 10^{-3}$), indicando que o grupo de condutores permanecem por mais tempo nesta faixa durante a chuva. O resultado do teste com reamostragem *bootstrap* evidenciou diferença estatisticamente significativa entre as condições, corroborando a tendência de aumento no tempo de permanência em velocidades reduzidas sob chuva. Tal padrão já havia sido sugerido tanto pela expansão do intervalo interquartil apresentado na Tabela 6.10 (de 5,14 para 5,84), quanto pela distribuição mais concentrada observada nos *boxplots* da Figura 6.2, sugerindo que, mesmo em velocidades reduzidas, a presença de chuva pode induzir um comportamento mais cauteloso ou conservador por parte dos motoristas. Esse padrão comportamental encontra respaldo na literatura. Sakhare *et al.* (2023) concluíram que a chuva intensa reduz a velocidade média do tráfego. Os referidos autores comprovaram que a cada incremento de 1mm/h na precipitação, aumenta a probabilidade de os condutores diminuírem sua velocidade em aproximadamente 5,8%. Essa discrepância entre os resultados encontrados sem e com a aplicação do *bootstrap* pode ser explicada pela capacidade do

bootstrap em capturar padrões sutis em dados com variabilidade, distribuição não normal ou amostras limitadas (Efron e Tibshirani, 1993).

A comparação entre os grupos V2 com chuva e V2 sem chuva, pela amostra original, não identificou diferença estatisticamente significativa no tempo de permanência nesta faixa ($Z = 0,46$; $p = 1,00$), sugerindo inicialmente que o grupo de condutores mantém comportamento semelhante, independentemente da presença de chuva. No entanto, a análise com reamostragem *bootstrap* revelou uma diferença significativa ($Z = 10,21$; $p = 1,84 \times 10^{-24}$). O Z-score positivo indica que o grupo de motoristas em V2 com chuva ficam por mais tempo nesta faixa em comparação com o grupo V2 sem chuva.

A Figura 6.2 mostra que, sob chuva, houve uma amplitude da caixa do *boxplot*, acompanhado de uma redução na presença de valores extremos. Esse padrão sugere aumento da variabilidade central, expressa pela elevação do IQR de 3,87% para 5,14%. A significância estatística identificada pelo teste de Dunn com *bootstrap* confirma essa diferença, evidenciando uma heterogeneidade sutil que já se delineava visualmente.

O aumento no tempo de permanência nesta faixa, sob chuva, pode indicar que o grupo de condutores adotou uma postura mais conservadora, evitando mudanças para faixas de maior ou menor velocidade. Isso pode estar associada ao desejo de minimizar riscos relacionados à redução da aderência do pavimento e à menor visibilidade, condições típicas de ambientes chuvosos, conforme apontado por Cai *et al.* (2013), que identificaram uma propensão dos motoristas a adotar condutas mais conservadoras sob chuva, incluindo a redução de manobras como trocas de faixa. A ampliação do intervalo interquartil e a significância estatística obtida confirmaram a heterogeneidade de respostas dentro de uma mesma faixa de velocidade. De acordo com Gonçalves e Silva (2018), a presença de chuva influencia o comportamento coletivo dos condutores, embora essa resposta possa variar em função da percepção de risco e da experiência de condução. Desse modo, verificou-se que a chuva não apenas modificou os níveis médios de velocidade, mas também ampliou a dispersão comportamental, evidenciando múltiplas estratégias adaptativas diante de condições climáticas adversas.

A comparação entre os grupos V3 com chuva e V3 sem chuva, considerando os dados da amostra original, não revelou diferença estatisticamente significativa no tempo de permanência na faixa ($Z = 0,82$; $p = 1,00$). Entretanto, a análise com o *bootstrap* identificou diferença altamente significativa ($Z = -20,60$; $p = 4,51 \times 10^{-94}$). O valor negativo do Z-score obtido no teste de Dunn com reamostragem *bootstrap* indica que, sob condição de chuva, os

condutores permaneceram, em média, por menos tempo na faixa de velocidades mais elevadas (%V3), em comparação à condição sem chuva

O valor negativo do Z-score obtido no teste de Dunn com reamostragem *bootstrap* indica que, sob condição de chuva, o grupo de condutores apresentou menor tempo médio de permanência na faixa de velocidades mais elevadas (V3), em comparação à condição sem chuva. Embora a caixa do boxplot permaneça estreita em ambas as situações, observou-se aumento no intervalo interquartil, de 0,75% para 1,40%, acompanhado de uma cauda superior mais alongada na distribuição dos dados com chuva, conforme evidenciado na Figura 6.2. Essa configuração sugere maior variabilidade pontual nas velocidades elevadas. A diferença foi confirmada como estatisticamente significativa pelo teste com reamostragem, indicando que, mesmo diante de valores percentuais absolutos reduzidos, há indícios de menor tempo de exposição em V3 sob chuva. Tal resultado reforça a hipótese de que a condição adversa impacta o padrão de condução, mesmo nos intervalos superiores de velocidade. O menor tempo de permanência na faixa em V3 com chuva pode ser resposta coletiva ao aumento do risco percebido devido à menor aderência e visibilidade. Já em V3 sem chuva, as condições mais favoráveis permitem uma condução mais contínua e estável. Esse resultado é coerente com Ghasemzadeh e Ahmed (2017), que observaram maior instabilidade na manutenção da faixa sob chuva em altas velocidades, exigindo correções frequentes na direção. Também se alinha a Das *et al.* (2022), que identificaram aumento da reatividade e redução da previsibilidade na condução em contextos chuvosos, o que pode justificar o menor tempo de permanência na faixa V3 sob essas condições.

A Tabela 6.14 também mostra que a amostra original não apresentou diferença estatisticamente significativa ($p = 0,365$) ao comparar os grupos V2 com chuva e V3 com chuva, o que sugere que os condutores mantiveram comportamento semelhante em velocidades próximas e acima do limite, mesmo sob condição de chuva. O valor de Z (1,33) reforça a baixa magnitude da diferença observada, sem indícios de alteração na distribuição do tempo entre essas faixas de velocidade. No entanto, a análise com reamostragem *bootstrap* revelou diferença estatisticamente significativa ($Z = 45,82$; $p < 0,001$), apontando uma tendência de permanência por mais tempo em velocidades moderadas (V2) do que excessivas (V3) durante a chuva, possivelmente como forma de adaptação à percepção de risco.

A diferença entre as faixas V2 e V3 sob chuva é compatível com a dispersão observada nos *boxplots* da Figura 6.2. Embora ambas as caixas estejam concentradas nos limites inferiores da escala, a faixa correspondente a V2 apresenta maior amplitude interquartil (5,14) em

comparação à de V3 (1,40), indicando maior tempo de permanência e variabilidade em velocidades próximas ao limite regulamentar. A significância estatística obtida por meio do teste de Dunn com reamostragem *bootstrap* corrobora essa tendência, sugerindo uma priorização mais consistente de velocidades moderadas em detrimento das faixas superiores sob condição adversa.

Na comparação entre os grupos V2 sem chuva e V3 sem chuva, tanto a amostra original ($Z = 6,46$; $p = 4,15 \times 10^{-10}$) quanto a análise com reamostragem *bootstrap* ($Z = 27,10$; $p < 0,001$) indicaram diferença estatisticamente significativa, sugerindo que, em condições de tempo seco, os condutores tendem a permanecer mais tempo na faixa V2 do que em V3. Assim, é possível constatar que independente das condições climáticas, o tempo de permanência em V2 é superior ao V3. Essa tendência é corroborada por estudos como de Budzyński *et al* (2022) e Islam *et al.* (2015) que apontaram que os condutores, de modo geral, adotam estratégias mais conservadoras de velocidade frente à percepção de risco viário, mesmo em boas condições de visibilidade e aderência. A análise descritiva corrobora essa diferença: o intervalo interquartil de V2 na condição sem chuva foi de 3,87%, enquanto para V3 o valor observado foi de 0,75%. Essa discrepância é visualmente representada na Figura 6.2 por meio de uma caixa mais ampla e maior incidência de valores extremos em V2, sugerindo maior tempo de exposição e variabilidade na faixa intermediária de velocidade, mesmo em condições de pista seca.

Em condições adversas, como a ocorrência de chuva, ainda que a significância estatística não seja evidente na análise da amostra original, a aplicação de métodos mais robustos, como o *bootstrap*, permite capturar padrões de resposta adaptativa menos evidentes. Conforme argumentam Bakhshi *et al.* (2022), tais adaptações não seguem um padrão linear e homogêneo entre os indivíduos, reforçando a importância de técnicas que considerem a variabilidade intraindividual do comportamento ao volante.

Para aceleração e frenagem, como não foi verificada normalidade pelos testes de *Shapiro-Wilk* ou *D'Agostino-Pearson* - ($p\text{-valor} < 0,05$), aplicou-se o teste não paramétrico de *U-Mann-Whitney* ($\alpha = 0,05$). A Tabela 6.15 apresenta os p-valores obtidos para cada variável, considerando as condições de tempo seco e chuvoso.

Tabela 6.15 Teste de U Mann-Whitney aplicado às condições de chuva e sua ausência.

Variável	Condição	Amostra original p-valor	<i>bootstrap</i> (BCa)p-valor
A1	Sem Chuva	0,0128 ¹	0,000 ¹
	Com Chuva		
A2	Sem Chuva	0,4651 ²	0,0002 ¹
	Com Chuva		

F1	Sem Chuva	0,0445 ¹	0,000 ¹
	Com Chuva		
F2	Sem Chuva	0,7344 ²	0,000 ¹
	Com Chuva		

¹Diferença significativa; ²Não há diferença significativa.

Conforme apresentado na Tabela 6.15, verificou-se diferença estatisticamente significativa em A1 ($0 \leq a \leq 1,5 \text{ m/s}^2$) entre as condições seca e molhada, tanto na amostra original ($p = 0,0128$) quanto com o *bootstrap* ($p < 0,0001$). Os valores descritivos indicaram redução da média (45,1% para 36,3%) e da mediana (47,7% para 36,1%), associada ao aumento do IQR (17,92% para 21,73%), sugerindo menor permanência em acelerações normais e maior heterogeneidade sob chuva.

Em A2 ($a > 1,5 \text{ m/s}^2$), a diferença não foi significativa na amostra original ($p = 0,4651$), mas foi confirmada pelo *bootstrap* ($p = 0,0002$). A média aumentou de 6,02% para 9,07%, enquanto a mediana manteve-se estável (1,70% para 1,65%), acompanhada da expansão do IQR (10,63% para 17,09%). Esse padrão indica maior ocorrência de valores extremos e aumento da variabilidade sob condição adversa, ainda que a maioria dos condutores mantenha baixa exposição a acelerações intensas.

Esses resultados sugerem que, sob condições de baixa aderência e visibilidade, os condutores reduzem o uso de acelerações normais (A1) e apresentam maior permanência em acelerações intensas (A2), refletindo uma adaptação comportamental que privilegia respostas reativas a perdas pontuais de tração. Li *et al.* (2015) e Yeo *et al.* (2021) corroboram tais resultados, destacando que superfícies molhadas diminuem o coeficiente de atrito, aumentando a frequência de acelerações abruptas, fenômeno observado de forma mais sensível pela reamostragem *bootstrap*. A Figura 6.2 ilustra esse padrão ao mostrar que, sob chuva, a caixa do boxplot se alarga visivelmente, refletindo um aumento do IQR de 12,70% para 17,15%. Esse alargamento indica que os valores médios de tempo em aceleração abrupta passaram a se distribuir de forma mais ampla entre os condutores. Além disso, observa-se uma cauda superior mais longa, sugerindo que, embora a maior parte do grupo tenha mantido valores moderados, uma parcela dos condutores passou a realizar acelerações intensas com maior frequência.

Em relação à porcentagem de tempo em frenagens normais (F1), ou seja, $-1,5 \text{ m/s}^2 \leq \text{frenagens} \leq 0 \text{ m/s}^2$, foi identificada diferença estatisticamente significativa entre as condições seca e molhada, tanto na amostra original ($p = 0,0445$) quanto no *bootstrap* ($p < 0,001$). A estatística descritiva indicou redução da mediana de F1 de 39,6 % (sem chuva) para 32,3 % (chuva), evidenciando menor permanência em desacelerações moderadas sob chuva. O

estreitamento do IQR em F1, evidenciado na Figura 6.2, sugere diminuição relativa da variabilidade central, indicando que a maioria dos condutores manteve padrões mais uniformes nesse tipo de frenagem. Esse resultado é consistente com Ahmed *et al.* (2021), que observaram maior uniformidade no comportamento de condução em ambientes adversos, associada a ajustes generalizados frente à redução de aderência e visibilidade.

Em frenagens abruptas, F2 ($a < -1,5 \text{ m/s}^2$), o teste na amostra original não apresentou diferença significativa ($p = 0,7344$), mas o *bootstrap* identificou efeito relevante ($p < 0,001$). Além disso, a média em F2 aumentou de 6,28 % para 8,08 % em pista molhada, sinalizando maior tempo dedicado a frenagens abruptas nesta condição. A Figura 6.2 ainda indica um alargamento da caixa sob chuva, com aumento do IQR de 13,66% para 16,67%. Esse padrão é consistente com Ahmed e Ghasemzadeh (2018), que identificaram maior instabilidade no controle veicular e aumento da ocorrência de frenagens abruptas em condições de chuva intensa. Resultados semelhantes foram apresentados por Yeo *et al.* (2021), ao evidenciarem que a variabilidade nas respostas de frenagem e aceleração aumenta em ambientes chuvosos, refletindo estratégias adaptativas distintas entre os condutores.

O decréscimo do tempo de permanência observado em F1 gera incremento relativo em F2, indicando que as desacelerações estáveis tendem a ser substituídas por respostas mais intensas quando a aderência e a visibilidade se deterioram. Essa interpretação é consistente com o que foi relatado por Mecarozzi *et al.* (2020), ao evidenciar que a redução do coeficiente de atrito em condições adversas induz a ocorrência de frenagens mais instáveis e abruptas, resultantes tanto do encurtamento do tempo de reação quanto da maior imprevisibilidade do tráfego.

Além da hipótese 1, cujo resultado foi apresentado anteriormente, para atingir os objetivos deste trabalho também foi testada a seguinte hipótese:

Hipótese 2: A combinação de precipitação e luminosidade, durante o dia e a noite, afeta a percentagem de tempo de permanência do condutor em cada faixa de velocidade, aceleração e frenagem investigada.

Esta hipótese investiga o percentual de tempo de permanência dos condutores em diferentes faixas de velocidade, aceleração e frenagem, considerando os efeitos combinados da precipitação e da iluminação natural (períodos diurno e noturno). A análise contempla três categorias de velocidade (V1, V2 e V3), duas de aceleração (A1 e A2) e duas de frenagem (F1 e F2), conforme o método apresentado no Capítulo 5.


A Tabela 6.16 apresenta a estatística descritiva da porcentagem de tempo de permanência em cada faixa de velocidade, aceleração e frenagem (diurno e noturno), sob chuva. São mostrados, para cada variável, os valores de média, mediana, desvio padrão, primeiro quartil (Q1), terceiro quartil (Q3) e intervalo interquartil (IQR), sem aplicação de técnicas de reamostragem (*bootstrap*), tomando-se por base a amostra original.

Tabela 6.16 Estatísticas descritivas: % V, A, F e IQR (dia e noite sob. chuva)

Categorias	Amostras (subviagens)	Condições Meteorológicas	Média (%)	Mediana (%)	Desvio Padrão (%)	Q1	Q3	IQR
V1	21	Diurno	95,88	97,78	4,68	93,69	100	6,31
	10	Noturno	96,07	97,02	4,05	94,87	99,07	4,20
V2	21	Diurno	3,22	1,38	3,94	0	5,58	5,58
	10	Noturno	2,89	2,2	2,83	0,77	4,14	3,38
V3	21	Diurno	0,91	0	1,38	0	1,73	1,73
	10	Noturno	1,03	0,51	1,51	0,24	0,97	0,73
A1	21	Diurno	33,14	36,08	22,05	26,09	47,69	21,60
	10	Noturno	42,89	36,38	14,37	32,14	51,37	19,23
A2	21	Diurno	7,26	1,5	10,75	0	14,87	14,87
	10	Noturno	12,88	15,86	10,94	1,27	22,62	21,35
F1	21	Diurno	29,38	36,02	20,13	8,7	42,96	34,27
	10	Noturno	32,62	28,53	9,71	25,86	42,67	16,81
F2	21	Diurno	6,41	2,31	8,46	0	11,85	11,85
	10	Noturno	11,61	16,54	9,32	1,48	17,9	16,42

Para complementar as estatísticas descritivas, foram elaborados *boxplots* com base na amostra original (Figura 6.3), sem reamostragem *bootstrap*.

Figura 6.3 Boxplot: % de tempo de permanência em faixas de V, A e F (Diurno e Noturno sob. chuva)



A Figura 6.3 mostra a variabilidade no comportamento dos condutores em diferentes períodos do dia (diurno e noturno), sob condições de chuva, com base na análise do intervalo interquartil (IQR).

A variável V1 (tempo com velocidade mais de 10% abaixo do limite máximo permitido) apresentou IQR maior no período diurno (6,31%) do que no noturno (4,2%). Em ambos os períodos, os dados se concentraram nos valores mais altos da escala, indicando predominância de velocidades significativamente abaixo do limite máximo pela via. A maior amplitude do IQR no período diurno sugere um comportamento mais heterogêneo entre os condutores, com adoção de diferentes padrões de velocidade mesmo se mantendo na faixa V1 ao longo do dia. Durante o dia, o campo visual ampliado possibilita diferentes decisões quanto à velocidade, com parte dos motoristas mantendo condutas mais prudentes e outros com comportamento mais heterogêneo mesmo dentro dessa faixa V1. A menor dispersão noturna e o deslocamento da mediana para valores superiores sugerem que, apesar da redução de velocidade ser comum em ambos os períodos, alguns condutores tendem a manter velocidades ainda mais baixas durante a noite, reforçando uma condução cautelosa sob iluminação reduzida.

Em V2 (tempo dentro da faixa de $\pm 10\%$ do limite máximo permitido na via), o IQR também foi maior no período diurno (5,58) quando comparado ao noturno (3,38). Isso indica que, sob chuva, a presença de luz natural amplia as possibilidades de interpretação do ambiente viário, o que resulta em maior diversidade de condutas. Conforme estudado por Warnakulasuriya *et al* (2025), a redução da visibilidade à noite tende a uniformizar os comportamentos, com menor variação nas respostas dos condutores. Assim, durante o dia, alguns motoristas mantêm velocidades abaixo do limite como forma de autoproteção, enquanto outros alternam breves retomadas para acompanhar o fluxo, modulando sua resposta conforme a leitura individual do contexto. À noite, esse comportamento tende a se estabilizar, com menor variação entre os condutores.

A variável V3 (tempo com velocidade mais de 10% acima do limite máximo da via) seguiu a mesma tendência, com IQR de 1,73% no período diurno e 0,73% no noturno, ambos sob chuva. A iluminação natural favorece a antecipação de situações viárias, o que pode induzir condutores a retomar a velocidade em trechos aparentemente seguros, mesmo sob chuva, como destacado por Schepers *et al.* (2025), que observaram maior propensão ao aumento da velocidade em segmentos visualmente abertos sob luz diurna. Em contraste, à noite, as limitações visuais atuam como inibidores naturais de comportamentos mais acelerados, como demonstrado por Tang *et al.* (2024), que identificaram uma queda sistemática nas velocidades médias e uma tendência à centralização na faixa sob condições de baixa visibilidade.

A análise da variável A1 (percentual do tempo com acelerações normais, $0 \leq a \leq 1,5 \text{ m/s}^2$) mostrou que, durante o período diurno, os condutores apresentaram um intervalo interquartil de 21,60, enquanto no período noturno esse valor foi de 19,23, ambos sob chuva. A maior variabilidade diurna nesse tipo de aceleração sugere um ambiente de condução mais dinâmico e com maiores demandas de modulação da velocidade. A configuração dos boxplots reforça esse padrão: a caixa referente ao período diurno foi mais alongada, refletindo a dispersão ampliada entre os condutores, enquanto no noturno, a distribuição foi mais compacta, com menor variabilidade entre os quartis. Estudos apontam que a chuva altera a percepção de risco e a aderência da via, influenciando a regularidade das acelerações (Wang *et al.*, 2021). De maneira semelhante, Moreira (2018) identificou que, em áreas urbanas sob precipitação, os condutores apresentaram maior variação coletiva nos níveis de aceleração em horários de maior visibilidade, ao passo que no período noturno os ajustes tenderam a ser mais homogêneos. Assim, a menor variabilidade noturna observada em A1 sugere uma convergência grupal de

respostas, possivelmente associada à limitação visual, que induz condutas mais uniformes de aceleração moderada.

Quanto a variável A2 (tempo com acelerações $> 1,5 \text{ m/s}^2$), os dados mostraram um IQR de 14,87 no período diurno e de 21,35 no noturno, ambos sob chuva. O aumento da variabilidade à noite indica um comportamento mais heterogêneo entre os condutores. Visualmente, a Figura 6.3 evidencia essa diferença ao mostrar caixa mais larga e caudas mais pronunciadas no período noturno, sugerindo maior oscilação no uso de acelerações abruptas entre os motoristas. Esse resultado indica que, coletivamente, os condutores oscilaram mais no uso de acelerações abruptas à noite, refletindo um comportamento grupal menos uniforme. A combinação entre pista molhada e baixa luminosidade reduz a previsibilidade das condições de condução, o que resulta em maior amplitude de respostas dentro do conjunto. Tang *et al.* (2023) apontam que a limitação visual intensifica a variabilidade coletiva das acelerações em cenários adversos, enquanto Yue *et al.* (2023) destacam que a heterogeneidade grupal se amplia em ambientes noturnos, exigindo maior dispersão nos parâmetros de modelagem. De forma semelhante, Osorio *et al.* (2015) demonstraram que o ajuste da aceleração em contextos de restrição visual constitui um fator crítico para explicar a instabilidade grupal observada. Dessa forma, o maior IQR encontrado à noite reflete uma tendência coletiva de comportamento mais heterogêneo do que no período diurno.

Em relação a variável F1 ($-1,5 \text{ m/s}^2 \leq \text{frenagem} \leq 0 \text{ m/s}^2$), observou-se o maior intervalo interquartil entre todas as variáveis analisadas: 34,27 no diurno e 16,81 no noturno, ambos sob chuva. Essa diferença é compatível com o padrão esperado para o contexto urbano sob chuva durante o dia, onde o volume de interações como semáforos, travessias e aproximações de veículos, obriga os condutores a realizarem reduções constantes e graduais de velocidade. A alta dispersão indica que, embora esse tipo de frenagem seja predominante, os condutores diferem amplamente quanto à frequência e duração dessas ações. No gráfico, o *boxplot* do período diurno (Figura 6.3) exibe uma caixa mais alongada e cauda inferior estendida, refletindo essa grande variação entre os indivíduos. No noturno, a diminuição das interações viárias favorece uma condução mais contínua e previsível, reduzindo a variabilidade nas frenagens normais. A restrição visual intensifica a instabilidade grupal no controle do veículo, aumentando a amplitude das respostas de desaceleração em ambientes noturnos (Retallack e Ostendorf, 2019; Tang *et al.*, 2023).

Para F2 (porcentagem de tempo com frenagens abruptas, a $< -1,5 \text{ m/s}^2$), que representa as frenagens bruscas, o IQR foi de 11,85 no diurno e 16,42 no noturno, ambos sob chuva. Essa

inversão de tendência aponta para maior variabilidade nas reações intensas de frenagem durante a noite. A menor visibilidade, a percepção tardia de obstáculos e a redução de referências visuais contribuem para decisões de frenagem mais abruptas e inconsistentes entre os condutores. Visualmente, essa dispersão é perceptível na Figura 6.3, com maior amplitude e presença de valores extremos no *boxplot* noturno, indicando oscilações mais acentuadas no comportamento de frenagem. Assim, os dados evidenciam que, no período noturno, os condutores adotaram estratégias mais diversas diante de situações que exigiram frenagens bruscas, caracterizando um comportamento menos uniforme sob essa condição. Tang *et al.* (2023) demonstraram que a restrição visual intensifica a dispersão das manobras de desaceleração, sobretudo em cenários de baixa previsibilidade. Hoffmann *et al.* (2003) reforçam que chuva e visibilidade reduzida constituem fatores determinantes para a heterogeneidade coletiva, resultando em padrões mais dispersos de frenagens bruscas. Assim, o maior IQR observado em F2 no período noturno confirma que, coletivamente, os condutores apresentaram comportamento menos uniforme na aplicação de frenagens abruptas.

Conforme os fluxogramas da Figura 5.4 e 5.5, foram aplicados testes de normalidade aos parâmetros de velocidade, aceleração e frenagem, nas condições diurna e noturna sob chuva. Utilizou-se o teste de D'Agostino-Pearson para amostras com mais de 50 observações e o teste de Shapiro-Wilk para amostras menores. Os respectivos p-valores encontram-se na Tabela 6.17.

Tabela 6.17 Teste de Normalidade: D'Agostino-Pearson ou de Shapiro-Wilk (diurno e noturno, sob chuva)

Velocidade	Período	p-valor amostra original
V1	Diurno	2,90e-03 ¹
	Noturno	8,10e-02 ²
V2	Diurno	3,19e-04 ¹
	Noturno	1,29e-01 ²
V3	Diurno	4,47e-05 ¹
	Noturno	3,47e-04 ¹
A1	Diurno	0,0561 ²
	Noturno	0,0456 ¹
A2	Diurno	0,0001 ¹
	Noturno	0,0420 ¹
F1	Diurno	0,0202 ¹
	Noturno	0,0551 ²
F2	Diurno	0,0003 ¹
	Noturno	0,0190 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Os resultados apresentados na Tabela 6.17 amostram que algumas variáveis apresentaram distribuição normal (V1 e V2 no noturno; A1 no diurno; F1 no noturno), enquanto as demais seguiram distribuição não normal. Conforme metodologia definida no capítulo anterior, adotou-se o teste de *Hodges-Lehmann* para a amostra original e o método *bootstrap* (BCa), com 2.000 réplicas, para a amostra reamostrada. A Tabela 6.18 apresenta os intervalos de confiança gerados por ambos os métodos, bem como suas respectivas amplitudes (A), calculadas com 95% de confiança a partir da diferença entre os limites superior e inferior.

Tabela 6.18. IC e A: amostras originais e com *bootstrap* para V, A e F (Diurno e Noturno, sob chuva)

Variável	Período	IC Original (Inferior; Superior)	Amplitude (%)	IC <i>bootstrap</i> BCa (Inferior; Superior)	Amplitude (%)
V1	Diurno	86,78; 100,00	13,22	94,66 ; 100,00	5,34
	Noturno	91,67; 100,00	8,33	94,59 ; 99,34	4,75
V2	Diurno	0,00; 7,14	7,14	0,00 ; 3,35	3,35
	Noturno	0,00; 5,56	5,56	0,53 ; 4,70	4,17
V3	Diurno	0,00; 1,75	1,75	0,00 ; 0,73	0,73
	Noturno	0,00; 0,77	0,77	0,44 ; 2,71	2,27
A1	Diurno	30,23; 56,00	25,77	27,90 ; 42,17	14,27
	Noturno	28,57; 52,00	23,43	31,88 ; 51,45	19,56
A2	Diurno	1,56; 24,00	22,44	0,00 ; 9,23	9,23
	Noturno	1,39; 23,26	21,87	1,15 ; 23,71	22,56
F1	Diurno	33,33; 53,33	20,0	25,00 ; 40,74	15,74
	Noturno	25,00; 46,67	21,67	25,02 ; 45,08	20,05
F2	Diurno	1,39; 18,06	16,67	0,00 ; 10,27	10,27
	Noturno	0,93; 17,59	16,66	1,20 ; 18,98	17,78

Os resultados da Tabela 6.18 indicam que o método *bootstrap* BCa gerou intervalos de confiança mais estreitos em comparação com o *Hodges-Lehmann*, proporcionando estimativas mais consistentes. Essa característica foi relatada por Sharafeldin *et al.* (2022), que destacaram a capacidade do BCa em reduzir distorções amostrais e aumentar a confiabilidade estatística.

Considerando que os testes de normalidade resultaram na rejeição da hipótese de distribuição normal, aplicou-se o teste não paramétrico de *Kruskal-Wallis*., conforme fluxograma apresentado na Figura 5.4. A Tabela 6.19 mostra os p-valores encontrados tanto para as amostras originais e com reamostragem.

Tabela 6.19 Teste não paramétrico de *Kruskal-Wallis*: velocidades (período diurno e noturno, sob chuva)

Teste	p-valor (amostra original)	p-valor (amostra BCa)
Kruskal-Wallis	1,16e-12 ¹	0,00e+00 ¹

¹Diferença significativa; ²Não há diferença significativa.

Os resultados do teste de *Kruskal-Wallis*, apresentados na Tabela 6.19, indicam que houve diferenças estatisticamente significativas entre os períodos diurno e noturno (*p-valores*

<0,05), ambos sob chuva. A técnica de *bootstrap* (BCa) confirmou essa tendência, reforçando os resultados.

Dado que o teste de *Kruskal-Wallis* apenas apresenta a existência de diferenças sem especificar onde elas ocorrem, foi conduzido um teste *pós-hoc* de Dunn, cujos os resultados estão apresentados na Tabela 6.20.

Tabela 6.20 Teste Dunn – Amostra Original e *bootstrap* (BCa) (Diurno vs noturno, ambos sob chuva)

Grupo1	Grupo2	Amostra original		Amostra <i>bootstrap</i>	
		Z-score	p-valor (Holm)	Z-score	p-valor (Holm)
V1_diurno	V1_noturno	0,1575	8,75e-01 ²	-2,6823	3,65e-03 ¹
V2_diurno	V2_noturno	-0,5140	1,00e+00 ²	3,7717	2,43e-04 ¹
V3_diurno	V3_noturno	-0,4743	1,00e+00 ²	-3,3289	8,71e-04 ¹
V2_diurno	V3_diurno	1,2310	1,00e+00 ²	39,2782	0,00e+00 ¹
V2_noturno	V3_noturno	0,8836	1,00e+00 ²	32,0477	4,72e-225 ¹

¹Diferença significativa; ²Não há diferença significativa.

A Tabela 6.20 mostra que, para a amostra original, não houve diferença estatística significativa ($Z = 0,16$; $p = 8,75e-01$) entre a faixa V1(mais de 10% abaixo do limite máximo permitido nas vias) nos períodos diurno e noturno, ambos sob chuva. Isso sugere que a distribuição do tempo de permanência nessa faixa foi praticamente a mesma entre os períodos. O Z-score próximo de zero reforça essa estabilidade, indicando que esses condutores mantiveram um padrão de condução cauteloso independentemente da luminosidade. No entanto, a aplicação do método *bootstrap* revelou diferença estatisticamente significativa ($Z = -2,68$; $p = 3,65e-03$), com o sinal negativo do escore Z apontando também um aumento no tempo de permanência na faixa V1 durante a noite. A redução da velocidade sob condições noturnas e de chuva pode ser atribuída à menor visibilidade, à percepção ampliada de risco de aquaplanagem e à imprevisibilidade do tráfego, o que induz os condutores a adotarem um comportamento mais cauteloso. Tal padrão é coerente com os estudos de Ebrahimi Darkhaneh *et al.* (2025), Wang *et al.* (2024) e Warnakulasuriya *et al.* (2025), que associam essas condições a maior gravidade de acidentes, perda de visibilidade de faixas e sinais, e aumento do tempo de reação por parte do condutor.

Além disso, a faixa V1 sob chuva, apresentou diminuição do intervalo interquartil (IQR) de 6,31% no período diurno para 4,20% no noturno, indicando menor dispersão amostral e maior uniformidade de comportamento entre os condutores à noite. A Figura 6.3 auxilia nesta análise ao mostrar, no período noturno, uma caixa do *boxplot* mais compacta, com mediana levemente deslocada para valores mais altos, sugerindo maior concentração do tempo em

velocidades reduzidas. No período diurno, o *boxplot* apresentou maior amplitude interquartil, evidenciando estratégias mais heterogêneas sob iluminação natural.

Para a amostra original, a comparação dos motoristas que permaneceram no percentual de tempo de permanência na faixa V2 (velocidade dentro de $\pm 10\%$ da máxima permitida nas vias) durante o dia e a noite não apresentou diferença estatisticamente significativa ($Z = -0,51$; $p = 1,00$), sugerindo que a distribuição do tempo de permanência nessa faixa foi praticamente a mesma entre os períodos. No entanto, o *bootstrap* revelou uma diferença significativa ($Z = 3,77$; $p = 2,43e-04$), indicando que, embora a média pareça estável, houve uma leve tendência de variação no tempo de permanência nessa faixa à noite. O aumento do Z-score sugere que, para alguns motoristas, o tempo de permanência dentro dessa faixa pode se alterar ligeiramente devido a mudanças na percepção de risco ou às condições do tráfego noturno. Tal resultado é compatível com a variação do intervalo interquartil, que passou de 5,58% no período diurno para 3,38% à noite, evidenciando uma leve contração da dispersão no segundo caso.

A Figura 6.3 reflete essa mudança ao mostrar uma caixa mais extensa durante o dia, com valores mais distribuídos ao redor da mediana. No período noturno, observa-se um encurtamento da caixa e uma mediana levemente inferior, sugerindo que os condutores tenderam a manter velocidades um pouco mais baixas e com menor variabilidade. Esses resultados indicam que, embora a média de tempo em V2 permaneça próxima entre os períodos, a combinação de chuva e baixa luminosidade noturna promoveu maior uniformidade nas decisões de velocidade. Essa convergência comportamental sob baixa visibilidade também foi observada por Wang *et al.*, (2025), que identificaram que ambientes noturnos e chuvosos tendem a reduzir a variabilidade nas manobras dos condutores, promovendo ações mais cautelosas e consistentes.

A comparação entre a percentagem de tempo de permanência na faixa V3 (percentual de tempo em velocidades mais de 10% acima do limite máximo permitido na via) no período diurno e noturno não apresentou diferença estatística na análise original ($Z = -0,47$; $p = 1,00$), indicando que os condutores que dirigem acima do limite mantiveram esse comportamento independentemente do período do dia. No entanto, o *bootstrap* revelou uma diferença significativa ($Z = -3,32$; $p = 8,71e-04$). O Z-score negativo sugere uma leve tendência de redução da velocidade à noite. Isso indica que, embora os condutores que excedem o limite de velocidade da via durante o dia continuem dirigindo rápido à noite, houve uma leve adaptação à visibilidade reduzida e à percepção de risco sob chuva, resultando em um tempo de permanência menor nessa faixa no período noturno. Essa diferença estatisticamente

significativa encontra respaldo na redução do intervalo interquartil, que passou de 1,73% no período diurno para 0,73% no noturno. Conforme apresentado na Figura 6.3, a caixa do boxplot tornou-se mais compacta à noite, com mediana ligeiramente inferior, indicando menor tempo de permanência em velocidades excessivas. A menor dispersão noturna sugere uma convergência comportamental, com os condutores adotando velocidades mais moderadas. Essa adaptação, ainda que sutil, reforça a hipótese de que a percepção de risco intensificada pelas condições ambientais inibe comportamentos de alta velocidade, como demonstrado por Ebrahimi Darkhaneh *et al.* (2025), que associam cenários noturnos e chuvosos ao aumento da gravidade dos acidentes. Da mesma forma, Nitsche *et al.* (2025) destacam que ambientes com baixa iluminação reduzem a capacidade de antecipação do condutor, levando à contenção espontânea da velocidade. Além disso, Wang *et al.* (2025) observaram que a perda da visibilidade de sinalizações e limites à noite influencia na decisão dos motoristas de adotar estratégias mais conservadoras.

Na comparação entre as faixas V2 e V3 no período diurno, a amostra original não apresentou diferença estatisticamente significativa ($Z = 1,23$; $p = 1,00$), sugerindo que, sob chuva, os condutores que permanecem dentro do limite de velocidade (V2) e aqueles que excedem o limite em mais de 10% (V3) mantiveram comportamentos próximos. Contudo, após a aplicação do *bootstrap*, verificou-se uma diferença altamente significativa ($Z = 39,28$; $p < 0,001$). Esse resultado indica que, embora o teste tradicional não tenha capturado distinções, a análise com reamostragem revelou que, em ambiente chuvoso, há uma redistribuição do tempo de permanência entre condução dentro do limite e em alta velocidade, evidenciando maior sensibilidade do método *bootstrap* para identificar padrões de adaptação dos condutores. O *bootstrap* revelou diferenças significativas entre condução dentro do limite (V2) e acima do limite (V3). Isso pode estar relacionado ao fato de que, mesmo durante o dia, condições de chuva afetam a percepção de risco e a visibilidade, levando parte dos condutores a reduzir a velocidade. Warnakulasuriya *et al.* (2025) destacam que ambientes chuvosos reduzem a clareza de marcações viárias e ampliam a necessidade de ajustes na condução. Assim, a redistribuição observada entre V2 e V3 no período diurno pode refletir essa necessidade de adaptação diferenciada entre condutores.

Situação análoga foi observada no período noturno, em que a amostra original também não apresentou diferenças estatísticas entre as faixas V2 e V3 ($Z = 0,88$; $p = 1,00$). No entanto, o *bootstrap* novamente indicou distinção significativa ($Z = 32,05$; $p < 0,001$), sugerindo que os condutores ajustam seu comportamento de maneira distinta sob baixa luminosidade. Esse

resultado demonstra que, mesmo em condições de visibilidade reduzida, parte dos condutores mantém a prática de trafegar em velocidades superiores ao limite da via, ao passo que outros tendem a permanecer na faixa de conformidade, ampliando a variabilidade do comportamento e confirmando a presença de estratégias divergentes de condução em ambiente adverso. No noturno, a diferença também foi captada apenas pelo *bootstrap*, indicando que a combinação de baixa luminosidade e chuva potencializa a divergência de estratégias de condução. Gonzalez *et al.* (2007) identificaram que clima adverso altera a escolha de rota e o padrão de velocidade, corroborando a dispersão maior observada.

Com base no fluxograma apresentado na Figura 5.5, após a verificação da não normalidade e a análise intervalo de confiança, procedeu-se com a aplicação de testes não paramétricos. Assim, o teste de U Mann-Whitney ($\alpha = 0,05$) foi usado tanto às amostras originais quanto às geradas pelo *bootstrap* (BCa), possibilitando a comparação das abordagens e a verificação da estabilidade das inferências estatísticas. Os *p-valores* obtidos para cada variável, considerando os períodos diurno e noturno, sob chuva, estão apresentados na Tabela 6.21.

Tabela 6.21 Teste de U Mann-Whitney aplicado períodos Diurno e Noturno sob. chuva

Variável	Condição	U-Mann-Whitney amostra original p-valores	U-Mann-Whitney <i>bootstrap</i> (BCa) p-valores
A1	Diurno	0,4587 ²	5,195e-57 ¹
	Noturno		
A2	Diurno	0,0579 ²	0,0000 ¹
	Noturno		
F1	Diurno	0,8489 ²	0,0000 ¹
	Noturno		
F2	Diurno	0,0628 ²	0,0000 ¹
	Noturno		

¹Diferença significativa; ²Não há diferença significativa.

Pela Tabela 6.21, observa-se que a comparação entre os períodos diurno e noturno quanto ao tempo de permanência em aceleração normal (A1), não apresentou diferença estatística significativa na amostra original ($p = 0,4587$), sugerindo que os condutores mantêm um padrão semelhante de aceleração normal independentemente da luminosidade. No entanto, a aplicação do método de reamostragem *bootstrap* revelou uma diferença significativa ($p = 5,20e-57$), indicando que a condução em A1 varia de forma consistente entre os períodos. Esse resultado corrobora os resultados gráficos, nos quais se observa uma maior dispersão (IQR) no período diurno de 21,60% em comparação ao noturno 19,23%. A maior heterogeneidade durante o dia pode estar associada à maior complexidade viária e ao volume de tráfego, exigindo

modulações mais frequentes da velocidade. À noite, a visibilidade reduzida e a menor densidade de tráfego favorecem um padrão de aceleração mais uniforme e previsível, resultando em menor variabilidade entre os condutores. A maior heterogeneidade durante o dia pode estar associada à maior complexidade viária e ao volume de tráfego, exigindo modulações mais frequentes da velocidade. Estudos de simulação confirmam que os parâmetros de aceleração e desaceleração são sensíveis às condições de densidade, variando conforme o contexto de tráfego e luminosidade (Tang *et al.*, 2023).

A variável A2 apresentou IQR de 14,87% no período diurno, passando para 21,35% no período noturno, ambos sob chuva. Embora a amostra original tenha apontado $p = 0,0579$ (não significativa), o *bootstrap* revelou uma diferença estatística significativa ($p = 0,0000$), sugerindo maior heterogeneidade noturna. Graficamente observa-se que a caixa mais extensa e as caudas mais acentuadas é consequência da maior oscilação comportamental sob chuva e escuridão. A ocorrência de acelerações abruptas à noite pode também estar relacionada a reações tardias frente a obstáculos ou cruzamentos pouco iluminados, exigindo respostas mais intensas para compensação (Faria *et al.*, 2020).

A análise conjunta das variáveis A1 e A2, ambos sob chuva, evidencia padrões complementares. Durante o período diurno, observou-se maior heterogeneidade nas acelerações normais (A1), resultado da complexidade viária e do tráfego mais intenso, que demandam ajustes constantes e modulações sutis de velocidade. No período noturno, a variabilidade se concentrou nas porcentagens de tempo em acelerações abruptas (A2), refletindo a existência de estratégias divergentes. A variabilidade do comportamento de aceleração aumenta em contextos de menor controle externo, como no tráfego noturno, devido à maior liberdade de escolha e às limitações perceptivas impostas pela baixa luminosidade (Kučina *et al.*, 2023).

A análise da amostra original para a variável F1 (frenagem normal) indicou ausência de diferença estatisticamente significativa entre os períodos diurno e noturno ($p = 0,8489$), sugerindo que os condutores mantiveram um padrão relativamente estável de frenagem sob chuva. Esse comportamento pode estar associado à necessidade de preservar a estabilidade do veículo em pista molhada, evitando desacelerações que aumentariam o risco de derrapagem (Rakha, 2009; Ferraz *et al.*, 2012). Após a aplicação do *bootstrap* (BCa), observou-se significância estatística ($p = 0,0000$), revelando diferenças sutis entre os períodos não identificadas na análise original. A reamostragem permitiu detectar variações comportamentais, indicando que o padrão de frenagem moderada se diferencia entre o dia e a noite, mesmo com tendência central semelhante.

Essa diferença pode ser explicada por fatores perceptivos e ambientais que afetam a condução noturna. A visibilidade reduzida pode limitar a antecipação de eventos, exigindo respostas mais rápidas e variações na intensidade da frenagem (Konstantopoulos *et al.*, 2010; Hassan *et al.*, 2014). Além disso, o menor fluxo de veículos à noite pode induzir a um comportamento menos regulado, com alternância entre condução contínua e freadas mais intensas (Jägerbrand e Sjöbergh, 2016).

Do ponto de vista descritivo, observou-se o maior intervalo interquartil entre todas as variáveis analisadas: 34,27% no período diurno e 16,81% no noturno, ambos sob chuva. Essa diferença é compatível com o padrão esperado para o contexto urbano sob chuva durante o dia, em que o volume de interações, como semáforos, travessias e aproximações de veículos obriga os condutores a realizarem reduções constantes e graduais de velocidade. A alta dispersão indica que, embora esse tipo de frenagem seja predominante, os condutores diferem amplamente quanto à frequência e duração dessas ações (Yeo *et al.* 2020).

A análise da frenagem abrupta (F2) revelou um comportamento semelhante ao observado nas acelerações abruptas (A2), com maior dispersão no período noturno. Embora a amostra original não tenha indicado diferença estatística significativa ($p = 0,0628$), a aplicação do *bootstrap* ($p = 0,0000$) mostrou uma variação entre os períodos. O IQR aumentou de 11,85% no diurno para 16,42% no noturno, refletindo uma maior variabilidade nas respostas de frenagem intensa. Essa dispersão noturna pode estar associada à visibilidade reduzida, à percepção tardia de obstáculos e à menor previsibilidade do ambiente viário. A Figura 6.2 reforça esse padrão ao exibir uma caixa mais longa e cauda superior mais pronunciada no noturno, sugerindo oscilações mais acentuadas entre os condutores. Esse comportamento menos uniforme pode resultar da dificuldade em antecipar situações críticas, da variabilidade na experiência dos motoristas e da influência da menor densidade de tráfego, que permite tanto a condução mais fluida quanto freadas reativas mais intensas.

Em conjunto, os resultados de F1 e F2 evidenciam que a variabilidade das frenagens se desloca do comportamento moderado para o extremo conforme o período. Durante o dia, a maior densidade de tráfego, as interações em semáforos e travessias exigem reduções graduais frequentes, resultando em maior dispersão entre condutores em F1. À noite, a menor previsibilidade e a limitação da visibilidade fazem com que a variabilidade se concentre nas respostas mais intensas, aumentando a heterogeneidade em F2. Esse padrão reforça a ideia de que a luminosidade modula não apenas a frequência, mas também a intensidade com que os condutores ajustam sua velocidade, em linha com observações de que ambientes com baixa

visibilidade induzem maior probabilidade de respostas bruscas, como frenagens repentinas (Schepers *et al.*, 2025).

Além das hipóteses 1 e 2, cujos resultados foram apresentados anteriormente, para atingir os objetivos deste trabalho também foi testada a seguinte hipótese:

Hipótese 3: A combinação de precipitação e o fluxo de veículos em diferentes horários, incluindo os picos e os entre picos de tráfego, afeta a percentagem de tempo de permanência do condutor em cada faixa de velocidade, aceleração e frenagem investigada.

Esta hipótese avalia a proporção de tempo de permanência dos condutores em diferentes faixas de velocidade, aceleração e frenagem, considerando os efeitos combinados da precipitação e dos períodos de pico e entre pico de tráfego. A análise contempla três categorias de velocidade (V1, V2 e V3), duas de aceleração (A1 e A2) e duas de frenagem (F1 e F2), em conformidade com o procedimento metodológico descrito no Capítulo 5.


A Tabela 6.22 apresenta a estatística descritiva contemplando os valores de média, mediana, desvio padrão, primeiro quartil (Q1), terceiro quartil (Q3) e intervalo interquartil (IQR), sem aplicação de técnicas de reamostragem (*bootstrap*), tomando-se por base a amostra original.

Tabela 6.22 Estatísticas descritivas: % V, A, F e IQR (Pico e entre picos, sob chuva)

Categorias	Amostras (subviagens)	Período	Média	Mediana	Desvio Padrão	Q1	Q3	IQR
V1	6	Pico	95,76	98,03	4,90	92,34	99,13	6,79
	25	Entre Picos	95,98	96,89	4,40	94,63	100	5,37
V2	6	Pico	3,58	1,43	4,29	0,63	7,07	6,44
	25	Entre Picos	3,00	1,69	3,48	0,00	4,70	4,70
V3	6	Pico	0,66	0,54	0,76	0,23	0,61	0,39
	25	Entre Picos	1,02	0,25	1,52	0,00	1,73	1,73
A1	6	Pico	43,12	44,93	9,79	37,6	50,27	12,67
	25	Entre Picos	34,65	33,17	21,8	29,25	51,22	21,97
A2	6	Pico	7,18	2,07	9,15	1,52	11,79	10,27
	25	Entre Picos	9,53	1,65	11,47	0,00	18,12	18,12
F1	6	Pico	43,07	45,82	9,84	38,41	47,11	8,71
	25	Entre Picos	27,39	27,78	17,5	21,48	39,33	17,85
F2	6	Pico	6,64	1,76	9,03	0,76	10,35	9,59
	25	Entre Picos	8,43	2,74	9,07	0,00	17,31	17,31

Com o objetivo de aprofundar a análise das estatísticas descritivas apresentadas na Tabela 6.22, foram construídos boxplots (Figura 6.4), os quais permitem uma representação gráfica da distribuição das variáveis.

Figura 6.4 Boxplot: % de tempo de permanência em faixas de V, A e F (Pico e entre picos, sob chuva)



A Figura 6.4 apresenta a distribuição da variável V1 (tempo com velocidade mais de 10% abaixo do limite máximo permitido) sob condições de chuva, comparando os períodos de pico e entre pico. O intervalo interquartil foi de 6,79% no pico e 5,37% no entre pico, Esse resultado mostra que, durante o pico, houve maior heterogeneidade no comportamento dos condutores, com parte permanecendo mais tempo em velocidades inferiores ao limite e outros variando de forma mais intensa em resposta às interações frequentes do fluxo denso. Para o entre pico, o menor IQR revela condutas mais uniformes, compatíveis com um cenário menos congestionado, em que as reduções de velocidade ocorrem de forma mais previsível. Esse padrão está em consonância com Moreira (2018), que identificou que a intensidade do tráfego influencia a variabilidade das velocidades, ampliando as diferenças entre condutores em condições de maior fluxo.

Em V2 (tempo dentro da faixa de $\pm 10\%$ do limite máximo permitido na via), sob chuva, observa-se que o intervalo interquartil foi de 6,44% no pico e 4,70% no entre pico, revelando maior dispersão no pico. Mesmo dentro da faixa regulamentar de velocidade, os condutores apresentaram maior heterogeneidade comportamental no período de pico. No entre pico, o menor IQR mostra condutas mais uniformes. Esse comportamento encontra respaldo em Essien *et al.* (2018), que apontaram maior volatilidade no uso da velocidade em períodos de pico, enquanto no entre pico predominaram respostas mais estáveis.

Em V3 (porcentagem de tempo acima de 10% do limite máximo de velocidade da via) sob chuva, o intervalo interquartil foi de 0,39% no pico e 1,73% no entre pico, revelando maior dispersão no entre pico. Esse resultado indica que, embora o excesso de velocidade tenha ocorrido de forma pouco frequente, a variabilidade entre os condutores foi mais acentuada fora dos horários de maior demanda. A menor densidade viária característica do entre pico ampliou a liberdade de escolha dos motoristas, favorecendo estratégias de condução mais heterogêneas. Esse padrão está alinhado com Gonzalez *et al.* (2007), que destacaram que, em condições viárias menos restritivas, os condutores tendem a adotar estratégias mais diversas, incluindo a prática de exceder os limites de velocidade.

Para a variável A1 (aceleração normal, $0 \leq a \leq 1,5 \text{ m/s}^2$), o intervalo interquartil apresentou valores de 12,67% no pico e 21,97% no entre pico, ambos sob condição de chuva. Esse resultado demonstra que, fora dos horários de maior fluxo, o grupo de condutores apresentou comportamento mais heterogêneo, refletindo uma distribuição menos uniforme no uso de acelerações moderadas. Tal comportamento sugere que, fora dos horários de maior fluxo, a dinâmica do tráfego se caracteriza por ajustes de velocidade mais variados, refletindo uma condução globalmente menos homogênea. Isso foi observado por Faria *et al.* (2020) que episódios de aceleração em cenários chuvosos tendem a ampliar a variabilidade operacional do tráfego, refletindo instabilidade coletiva

Em A2 sob chuva, comparando os períodos de pico e entre pico. O intervalo interquartil do percentual de tempo em acelerações acima de $1,5 \text{ m/s}^2$ foi de 10,27% no pico e 18,12% no entre pico, evidenciando maior dispersão no entre pico. As acelerações abruptas correspondem a retomadas rápidas, associadas a manobras de ultrapassagem, retomada após frenagens ou resposta imediata a variações do fluxo. O maior IQR no entre pico indica que, em um tráfego mais fluido, o grupo de motoristas que utilizaram essa faixa de aceleração exploraram a liberdade viária para acelerar de forma mais agressiva, gerando maior heterogeneidade comportamental no entre pico. No pico, a elevada densidade de veículos restringe as possibilidades de aceleração intensa, o que reduz a variabilidade observada. Esse padrão é consistente com Tang *et al.* (2023), que apontaram que as respostas de aceleração tendem a apresentar maior dispersão em cenários de menor restrição viária, sobretudo quando combinados a condições ambientais adversas.

O intervalo interquartil de F1 (percentagem de tempo com frenagens normais $-1,5 \text{ m/s}^2 \leq \text{aceleração} < 0 \text{ m/s}^2$) foi de 8,71% no pico e 17,85% no entre pico, sob chuva. Esse resultado indica maior dispersão no entre pico, sugerindo diferenças mais acentuadas no modo como o

grupo de condutores executam reduções graduais de velocidade nesse período. A maior variabilidade observada no entre pico reflete que, em tráfego menos denso, os motoristas realizam correções frequentes e leves. No pico, a densidade viária impõe maior homogeneidade na frequência das frenagens. Rakha (2009) observou que sob chuva os condutores tendem a aumentar a distância de segurança e a reduzir a velocidade, impactando no fluxo de tráfego e a uniformidade das frenagens. Essa adaptação coletiva reduz a agressividade, mas também amplia a frequência de pequenas correções na velocidade, sobretudo fora dos horários de pico.

O intervalo interquartil de F2 , (percentagem de tempo com frenagens abruptas aceleração $< -1,5 \text{ m/s}^2$), foi de 9,59% no pico e 17,31% no entre pico, ambos sob chuva. O maior IQR no entre pico indica maior dispersão no uso desse tipo de desaceleração, revelando que, em tráfego mais livre, o grupo de condutores apresentou respostas mais heterogêneas. No pico, a densidade do fluxo atuou como fator regulador, restringindo a possibilidade de manobras bruscas e resultando em menor variabilidade. De forma semelhante, Elyoussoufi *et al.* (2023) destacam que a influência da chuva se manifesta de forma mais expressiva em períodos de menor densidade viária, quando há maior liberdade de manobra, ampliando a variabilidade coletiva dos padrões de desaceleração.

Conforme os fluxogramas da Figura 5.4 e 5.5, foram aplicados testes de normalidade aos parâmetros de velocidade, aceleração e frenagem, nas condições de pico e entre picos sob chuva. Utilizou-se o teste de D'Agostino-Pearson para amostras com mais de 50 observações e o teste de Shapiro-Wilk para amostras menores. Os respectivos p-valores encontram-se na Tabela 6.23.

Tabela 6.23 Teste de Normalidade: D'Agostino-Pearson ou de Shapiro-Wilk (Pico e Entre pico, sob chuva)

Velocidade	Período	p-valor amostra original
V1	Pico	8,02e-02 ²
	Entre Picos	1,82e-03 ¹
V2	Pico	2,97e-02 ¹
	Entre Picos	5,29e-04 ¹
V3	Pico	4,93e-02 ¹
	Entre Picos	1,01e-05 ¹
A1	Pico	0,0274 ¹
	Entre Picos	0,0703 ²
A2	Pico	0,0001 ¹
	Entre Picos	0,0005 ¹
F1	Pico	0,0297 ¹
	Entre Picos	0,0508 ²
F2	Pico	0,0001 ¹
	Entre Picos	0,0003 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

A Tabela 6.23 mostra que apenas algumas variáveis seguiram distribuição normal (V1 e V2 no noturno; A1 no Entre Picos; F1 Entre Picos), enquanto as demais apresentaram distribuição não normal. Assim, conforme a metodologia do capítulo anterior, aplicou-se o teste de *Hodges-Lehmann* à amostra original e o *bootstrap* BCa (2.000 réplicas) à amostra reamostrada.

A Tabela 6.24 apresenta os intervalos de confiança gerados por ambos os métodos, bem como suas respectivas amplitudes (A), calculadas com 95% de confiança a partir da diferença entre os limites superior e inferior

Tabela 6.24 IC e A: amostras originais com bootstrap para V, A e F (Pico e entre pico, sob chuva)

Variável	Período	IC Original (Inferior; Superior)	A (%)	IC <i>bootstrap</i> BCa (Inferior; Superior)	A (%)
V1	Pico	77,04 ; 100,00	22,96	91,23 ; 98,84	7,61
	Entre picos	84,96 ; 100,00	15,04	94,00 ; 97,50	3,50
V2	Pico	0,00 ; 7,96	7,96	0,82 ; 7,65	6,83
	Entre picos	0,00 ; 10,95	10,95	1,84 ; 4,54	2,69
V3	Pico	0,00 ; 18,36	18,36	0,27 ; 1,50	1,23
	Entre picos	0,00 ; 6,12	6,12	0,55 ; 1,79	1,23
A1	Pico	28,44 ; 64,70	36,26	43,78 ; 46,75	2,96
	Entre Picos	16,27 ; 69,11	52,84	41,77 ; 47,58	5,81
A2	Pico	0,05 ; 24,14	24,09	29,09 ; 35,24	6,15
	Entre Picos	0,00 ; 20,24	20,24	29,80 ; 42,39	12,58
F1	Pico	24,77 ; 51,95	27,17	43,78 ; 46,75	2,96
	Entre Picos	12,84 ; 51,22	38,38	41,77 ; 47,58	5,81
F2	Pico	0,37 ; 20,62	20,25	29,09 ; 35,24	6,15
	Entre Picos	0,00 ; 18,94	18,94	29,80 ; 42,39	12,58

A Tabela 6.24 mostra que o método *bootstrap* BCa produziu intervalos de confiança mais estreitos que o *Hodges-Lehmann*, aumentando a consistência das estimativas, conforme apontado por Sharafeldin *et al.* (2022). Como os testes rejeitaram a normalidade, aplicou-se o teste não paramétrico de Kruskal-Wallis (Figura 5.4). A Tabela 6.25 apresenta os p-valores obtidos para as amostras originais e reamostradas.

Tabela 6.25 Teste não paramétrico de Kruskal-Wallis: velocidades (pico e entre picos, sob chuva)

Teste	p-valor (amostra original)	p-valor (amostra BCa)
Kruskal-Wallis	0,00e+00 ¹	0,00e+00 ¹

¹Diferença significativa; ²Não há diferença significativa.

Conforme mostra a Tabela 6.25, o teste de *Kruskal-Wallis* apresentou significância estatística com p-valores próximos de zero ($p < 0,01$), indicando diferenças no comportamento dos condutores entre condições com e sem chuva. De forma complementar, o p-valor obtido pelo método *bootstrap* (BCa) corrobora esses resultados.

Dado que o referido teste apresenta a existência de diferenças sem especificar onde elas ocorrem, foi conduzido um teste pós-hoc de Dunn, conforme fluxograma apresentado na Figura 5.4. Esse teste permite realizar comparações múltiplas entre os grupos, identificando quais pares apresentam diferenças significativas. Os resultados destas comparações (resultantes do teste de Dunn) estão apresentados na Tabela 6.26.

Tabela 6.26. Teste Dunn – Amostra Original e com *bootstrap* (período pico e entre picos, sob chuva)

Grupo1	Grupo2	Amostra original		Amostra original <i>bootstrap</i>	
		Z-score	p-valor (Holm)	Z-score	p-valor (Holm)
V1_entre picos	V1_pico	0,0508	9.59e-01 ²	1,9236	2.72e-02 ¹
V2_entre picos	V2_pico	-0,2209	8.25e-01 ²	-3,8461	6.00e-05 ¹
V3_entre picos	V3_pico	-0,1011	9.19e-01 ²	19,3154	5.98e-83 ¹
V2_entre picos	V3_entre picos	1,3233	1,00e+00 ²	43,9050	0,00e+00 ¹
V2_pico	V3_pico	0,7425	1,00e+00 ²	66,2617	0,00e+00 ¹

¹Diferença significativa; ²Não há diferença significativa.

Conforme a Tabela 6.26, a comparação inicial entre os períodos de pico e entre pico para a faixa V1 não indicou diferença estatisticamente significativa ($Z = 0,0508$; $p = 0,959$), resultado coerente com o padrão homogêneo sugerido pela estatística descritiva. Entretanto, a aplicação do método *bootstrap* revelou significância ($Z = 1,9236$; $p = 0,0272$), confirmando maior permanência em V1 no entre pico. Esse resultado reforça que, em condição chuvosa, o grupo de condutores tende a manter velocidades reduzidas de forma consistente quando há menor fluxo de tráfego, enquanto no pico as frequentes interações provocadas pelo intenso fluxo de veículos (maior densidade) ampliam a variabilidade e geram diferentes respostas dentro da mesma faixa, conforme destacado por Moreira (2018), Retallack e Ostendorf (2019) e Tang *et al.* (2023). Assim, os testes estatísticos consolidaram a interpretação da estatística descritiva: sob chuva, o entre pico favorece condutas mais uniformes e prolongadas abaixo do limite de velocidade, enquanto o pico acentua a heterogeneidade do comportamento, evidenciando a influência direta das condições de tráfego sobre a estabilidade da condução.

A análise da variável V2 mostrou que, sob chuva, o grupo de condutores apresentou maior dispersão no período de pico (IQR = 6,44%) em comparação ao entre pico (IQR = 4,70%), indicando comportamento mais heterogêneo mesmo dentro da faixa regulamentar de velocidade ($\pm 10\%$). Na comparação estatística, a amostra original não revelou diferença significativa entre os períodos ($Z = -0,2209$; $p = 0,825$). Contudo, o *bootstrap* confirmou a existência de diferença ($Z = -3,8461$; $p = 0,00006$), apontando menor permanência em V2 durante o pico. Esse resultado reforça que, em condições de maior densidade veicular, os

condutores tendem a abandonar rapidamente a faixa intermediária de velocidade, adotando reduções mais acentuadas como estratégia de maior controle em pista molhada. Esse comportamento é consistente com estudos que destacam o efeito combinado entre clima e horário de tráfego. Nesse sentido, Essien *et al.* (2018) verificaram que a interação entre chuva e períodos de pico amplia a volatilidade no uso da velocidade, enquanto Stern *et al.* (2003) demonstraram que a elevada densidade intensifica os impactos das condições climáticas, reduzindo a permanência em velocidades intermediárias e favorecendo ajustes mais instáveis.

Em V3, a amostra original não revelou diferença significativa entre os períodos ($Z = -0,1011$; $p = 0,919$). Entretanto, a aplicação do *bootstrap* identificou variação altamente significativa ($Z = 19,3154$; $p < 0,001$), confirmando maior permanência do grupo de motoristas em excesso de velocidade durante o entre pico. Esse resultado reforça que a menor densidade viária amplia a liberdade de escolha, favorecendo tanto condutas cautelosas quanto estratégias mais agressivas, o que se traduz em maior dispersão. Esse padrão está em consonância com Gonzalez *et al.* (2007), que apontaram a adoção de estratégias mais diversas em contextos menos restritivos, bem como com Kilpeläinen e Summala (2007), que destacaram que nem todos os motoristas reduzem a velocidade sob chuva, e Ghasemzadeh e Ahmed (2017), que identificaram variabilidade na adaptação de velocidade em condições adversas.

A comparação entre V2 e V3 no período de entre pico não apresentou diferença estatisticamente significativa na amostra original ($Z = 1,3233$; $p = 0,1002$). Contudo, a reamostragem *bootstrap* revelou diferença significativa ($Z = 43,9050$; $p < 0,001$), indicando que o grupo de motoristas apresentou maior permanência em V2 em relação a V3. Esse resultado sugere que, mesmo em condições de menor densidade de tráfego, os condutores mantêm-se predominantemente em velocidades próximas ao limite máximo regulamentar da via, registrando menor ocorrência de excessos. A percepção de risco em ambientes de baixa aderência, como sob chuva, contribui para a priorização de margens adicionais de segurança, reduzindo a adoção de comportamentos extremos. A permanência reduzida em V3 confirma que o excesso de velocidade constitui uma conduta minoritária e mais heterogênea. Esses resultados estão em consonância com a literatura, segundo a qual a velocidade inapropriada, seja por excesso ou por reduções acentuadas, configura fator crítico para sinistros por comprometer o tempo de reação e ampliar a gravidade dos impactos (Etika *et al.*, 2023; Ferraz *et al.*, 2012). De forma complementar, Rozestraten (1988) e Hoffmann *et al.* (2003) destacam que condições ambientais adversas, como a chuva, funcionam como limitadores naturais à velocidade excessiva, favorecendo estratégias de condução mais conservadoras.

A comparação entre V2 e V3 no período de pico não apresentou diferença significativa na amostra original ($Z = 0,7425$; $p = 1,000$), sugerindo comportamento semelhante entre as duas faixas em condição de tráfego intenso. Contudo, o *bootstrap* revelou diferença significativa ($Z = 66,2617$; $p < 0,001$), confirmando que o grupo de condutores permaneceu mais tempo em V2 do que em V3. Esse resultado demonstra que, sob chuva e elevada densidade de tráfego, predomina a manutenção de velocidades próximas ao limite regulamentar, enquanto o excesso de velocidade assume caráter residual. O valor expressivo do Z-score no *bootstrap* reforça que a discrepância entre as faixas não é aleatória, mas reflete uma tendência coletiva por estratégias mais conservadoras. Esse padrão está em consonância com Elyoussoufi *et al.* (2023), que associaram a redução de velocidade sob condições adversas à compensação do risco percebido. De forma semelhante, Bakhshi *et al.* (2022) evidenciaram que a chuva reduz significativamente os comportamentos de alta velocidade e de violação das leis de trânsito, enquanto Stamos *et al.* (2016) destacaram que os efeitos da precipitação sobre a velocidade são mais pronunciados justamente em vias de maior fluxo, como nos horários de pico.

Com base no fluxograma apresentado na Figura 5.5, após a verificação da não normalidade e a análise intervalo de confiança, procedeu-se com a aplicação de testes não paramétricos. Assim, o teste de U Mann-Whitney ($\alpha = 0,05$) foi usado tanto às amostras originais quanto às geradas pelo *bootstrap* (BCa), possibilitando a comparação das abordagens e a verificação da estabilidade das inferências estatísticas. Os *p-valores* obtidos para cada variável, considerando os períodos diurno e noturno, sob chuva, estão apresentados na Tabela 6.27

Tabela 6.27 Teste de U Mann-Whitney aplicado períodos Pico e Entre pico, sob chuva

Variável	Condição	U-Mann-Whitney amostra original p-valores	U-Mann-Whitney <i>bootstrap</i> (BCa) p-valores
A1	Pico	0,013 ¹	0,00e+00 ¹
	Entre Picos		
A2	Pico	0,465 ²	3,020e-07 ¹
	Entre Picos		
F1	Pico	0,044 ¹	3,184e-106 ¹
	Entre Picos		
F2	Pico	0,734 ²	4,412e-23 ¹
	Entre Picos		

¹Diferença significativa; ²Não há diferença significativa.

Pela Tabela 6.27, observa-se que para A1, a comparação entre os períodos de pico e entre picos revelou diferença estatisticamente significativa na amostra original ($p = 0,013$), reforçada pela aplicação do *bootstrap* ($p = 0,0000$). Os resultados descritivos da Tabela 6.22

complementam esse resultado, indicando que a mediana de A1 foi superior no pico (44,93%) em relação ao entre pico (33,17%), ao passo que a dispersão foi menor (12,67 contra 21,97). Isso sugere que, durante o pico, a densidade de tráfego impõe um padrão de condução mais homogêneo de aceleração, restringindo variações bruscas. Já no entre pico, a menor densidade do tráfego aumenta a heterogeneidade de comportamento de condução, permitindo maior liberdade de modulação da velocidade. Esse comportamento é consistente com Elyoussoufi *et al.* (2023), que demonstraram que, em cenários de maior risco ou de tráfego intenso, os motoristas tendem a adotar padrões mais cautelosos e uniformes, enquanto em situações menos restritivas predominam respostas mais diversas. Assim, confirma-se que a menor variabilidade de A1 no pico decorre das limitações impostas pelo tráfego denso, ao passo que a dispersão ampliada no entre pico reflete a maior flexibilidade do grupo de condutores em pista molhada.

Para a variável A2 (acelerações bruscas, $a > 1,5 \text{ m/s}^2$) não foi identificada diferença estatisticamente significativa na amostra original ($p = 0,465$). No entanto, a aplicação do método de reamostragem *bootstrap* revelou diferença significativa ($p = 3,02\text{e-}07$), indicando que o comportamento em A2 varia de forma consistente entre os períodos. Os resultados da Tabela 6.22 mostram que a mediana de A2 foi maior no pico (2,07%) em comparação ao entre pico (1,65%), sugerindo que, em horários de maior densidade viária, as acelerações bruscas ocorrem de modo mais uniforme. Fora dos períodos de pico, a menor densidade do tráfego aumenta a heterogeneidade do comportamento, permitindo desde padrões mais suaves até respostas agressivas, o que explica a maior variabilidade observada. Esse resultado está em consonância com o estudo de Elyoussoufi *et al.* (2023) que constataram que em cenários de menor restrição viária prevalecem respostas mais heterogêneas, enquanto Tang *et al.* (2023) apontaram que, sob maior densidade, predomina-se um padrão coletivo mais concentrado.

Para a variável F1 (frenagens normais, $-1,5 \text{ m/s}^2 \leq a < 0 \text{ m/s}^2$), a comparação entre pico e entre pico apresentou diferença estatisticamente significativa na amostra original (U de Mann–Whitney, $p = 0,0441$), reforçada pelo *bootstrap* BCa ($p = 0,0000$). Os resultados da Tabela 6.22 mostram que a mediana de F1 foi superior no entre pico (20,48%) em relação ao pico (16,12%), enquanto a dispersão também foi maior (17,85 e 8,71, respectivamente). Esses resultados mostram que, fora dos horários de maior densidade, o grupo de condutores realizou frenagens graduais com maior frequência e variabilidade, refletindo maior liberdade para modulação da velocidade. Já no pico, a restrição imposta pelo tráfego intenso concentra o comportamento em padrões mais uniformes e previsíveis. Esse resultado está em consonância com Ferraz *et al.* (2012), que apontaram que em cenários de tráfego denso prevalecem respostas

mais homogêneas de desaceleração como forma de preservar a estabilidade e reduzir riscos, enquanto em condições menos restritivas há maior heterogeneidade de respostas.

Para a variável F2 (frenagens bruscas, $a < -1,5 \text{ m/s}^2$), a comparação entre os períodos de pico e entre pico não apresentou diferença significativa na amostra original ($p = 0,7342$). Entretanto, a aplicação do *bootstrap* (BCa) revelou significância elevada ($p = 4,41\text{e-}23$), confirmando que os padrões de frenagem brusca variam de forma consistente entre os dois contextos. Os resultados descritivos da Tabela 6.22 indicam que a dispersão foi maior no entre pico (IQR = 17,31%) em relação ao pico (IQR = 9,59%), revelando que, em condições de tráfego mais livre, o grupo de condutores adotou respostas mais heterogêneas de desaceleração intensa. No pico, a maior concentração de veículos limitou a ocorrência dessas manobras, resultando em comportamento mais homogêneo. Esse resultado encontra respaldo em Elyoussoufi *et al.* (2023), que destacaram que a influência da chuva é mais expressiva quando há maior liberdade de manobra, e em Kilpeläinen e Summala (2007), que observaram que as condições climáticas adversas não induzem respostas uniformes, já que parte dos condutores mantém condutas abruptas mesmo em pista molhada, ampliando a dispersão coletiva das frenagens.

6.9. Hipóteses 4, 5 e 6

Para complementar as análises globais realizadas nas três primeiras hipóteses, que avaliaram o comportamento dos motoristas em diferentes condições climáticas de forma agregada, foram investigadas de maneira individualizada as variações na velocidade, aceleração e frenagem de cada condutor em função das alterações nas condições climáticas (chuva e sem chuva), bem como nos períodos diurno e noturno, e nos horários de pico e entre pico, sob chuva.

A: Amostras

Nesse contexto, foi identificado o tempo de viagem em que cada condutor permaneceu em cada condições avaliadas, sendo elas: (i) com chuva e sem chuva, (ii) diurno ou noturno, com chuva e (iii) Pico e entre picos, com chuva. Para tal, utilizou-se o Python. O valor da amostra (s) encontra-se para cada situação investigada está apresentada na tabela com as estatísticas descritivas.

Pare seleção dos condutores avaliados nas hipóteses 4, 5 e 6, considerou-se os seguintes aspectos:

- Para avaliar o efeito na condução, o motorista realizou viagens tanto em condições de chuva quanto sem chuva.
- Para analisar a influência da luminosidade, sob planejamento, o condutor realizou viagens tanto durante o dia e a noite, ambos sob chuva.
- Para investigar os efeitos da variação no fluxo de veículos, sob chuva, o motorista realizou viagens nos períodos de pico e entre picos, ambos sob chuva.

B: Cálculo das Velocidades

Para analisar individualmente o comportamento dos motoristas em relação ao limite máximo de velocidade sob diferentes condições climáticas (com chuva e sem chuva), calculou-se a velocidade relativa adotada por cada motorista a cada segundo de viagem. Para tal, utilizou-se a linguagem Python, considerando:

- SPD_MPH: Velocidade do veículo em milhas por hora.
- SPD_KMH: Velocidade do veículo em quilômetros por hora.
- LIMITE_VEL: Limite de velocidade da via em que o veículo estava trafegando.

Com base nestas informações foi calculada a velocidade relativa a cada segundo de viagem, conforme recomendado no referencial teórico.

C: Resultados, Análises e Discussões

Hipótese 4: A precipitação afeta o desempenho individual do condutor em relação à velocidade, aceleração e frenagem?

Essa abordagem permite compreender o impacto das condições climáticas (com e sem chuva) no comportamento de cada motorista. Para testar essa hipótese, foram avaliados 16 motoristas, considerando apenas aqueles que realizaram deslocamentos sob ambas as condições: com chuva e sem chuva. Motoristas que não atenderam a esse critério foram excluídos da análise.

Insta salientar que neste estudo, a velocidade foi calculada com base na relação da diferença entre a velocidade instantânea e a máxima permitida na via pela velocidade máxima permitida. Esta métrica avalia o quanto cada condutor excede ou fica abaixo do limite de velocidade estabelecido para a via, oferecendo uma medida relativa que facilita a comparação entre diferentes vias. Tal abordagem permite compreender como as condições climáticas

influenciam a conformidade com os limites de velocidade e, conseqüentemente, o comportamento geral dos motoristas.


A Tabela 6.28 apresenta as estatísticas descritivas relacionadas à velocidade desses condutores, incluindo o tamanho da amostra (em segundos), bem como os valores das medianas e desvios padrão da velocidade.

Tabela 6.28. Estatística descritiva: velocidade individualizada (chuva e sem chuva)

Motorista	Condições Meteorológicas	Amostras (s)	Média	Mediana	Desvio Padrão
AC	Sem chuva	488	-0,9938	-0,9974	0,0307
	Com chuva	94	-0,9915	-0,9940	0,0077
AD	Sem chuva	1410	-0,9764	-0,9965	0,1275
	Com chuva	31	-0,9960	-0,9967	0,0032
AE	Sem chuva	20130	-0,3800	-0,3269	0,4802
	Com chuva	1468	-0,1766	-0,1895	0,4370
D	Sem chuva	1191	-0,9757	-0,9946	0,1317
	Com chuva	28	-0,9961	-0,9973	0,0035
F	Sem chuva	19220	-0,3730	-0,3828	0,5324
	Com chuva	40	0,0172	-0,0818	0,2917
H	Sem chuva	38974	-0,3119	-0,3212	0,3740
	Com chuva	1390	-0,2256	-0,2685	0,2901
I	Sem chuva	1153	-0,4837	-0,5435	0,4840
	Com chuva	21	-0,9642	-0,9971	0,0454
L	Sem chuva	37369	-0,4314	-0,3829	0,4498
	Com chuva	3758	-0,4866	-0,4143	0,4084
M	Sem chuva	20661	-0,3407	-0,2267	0,5042
	Com chuva	1608	-0,2225	-0,1548	0,3934
N	Sem chuva	8850	-0,4796	-0,5138	0,4868
	Com chuva	319	-0,2424	-0,2437	0,4883
O	Sem chuva	30246	-0,2905	-0,2559	0,4786
	Com chuva	1766	-0,3285	-0,2681	0,4159
P	Sem chuva	3157	-0,4504	-0,4296	0,4380
	Com chuva	135	-0,5789	-0,8067	0,4794
T	Sem chuva	28869	-0,3019	-0,2474	0,4909
	Com chuva	3464	-0,4013	-0,3672	0,4624
X	Sem chuva	39014	-0,9825	-1,0000	0,1073
	Com chuva	10375	-0,8815	-0,9960	0,3166
Y	Sem chuva	9903	-0,3500	-0,3213	0,5539
	Com chuva	3473	-0,2538	-0,1926	0,5429
Z	Sem chuva	6705	-0,5966	-0,8413	0,4695
	Com chuva	432	-0,6134	-0,8098	0,4286

Para complementar essa análise estatística descritiva, foi utilizada a representação gráfica por meio de *boxplots*, conforme ilustrado na Figura 6.5. O uso desse método permite a identificação de assimetria na distribuição dos dados, dispersão e presença de valores atípicos, além de viabilizar comparações diretas entre os períodos diurno e noturno. A interpretação conjunta dos resultados tabulares e gráficos contribui para uma compreensão mais detalhada das tendências observadas, auxiliando na verificação da hipótese levantada.

Figura 6.5 Boxplot: Velocidade Relativa de cada condutores (chuva e sem chuva)



Pela análise combinada da Figura 6.5 e da Tabela 6.28, observa-se que para os motoristas AC, AD e D, os valores médios e medianos da velocidade permaneceram próximos de -1, indicando pouca variação entre as condições de chuva e sem chuva. O desvio padrão desses condutores foi reduzido sob chuva, o que indica uma menor variabilidade na velocidade. O *boxplot* reforça essa constatação, apresentando *whiskers* mais curtos e uma distribuição mais concentrada, sugerindo que esses motoristas mantiveram um padrão de condução estável, independentemente da condição meteorológica.

O motorista AE apresentou um aumento na velocidade média e mediana sob chuva, com a média passando de -0,3800 para -0,1766 e a mediana de -0,3269 para -0,1895. Essa mudança sugere que esse condutor adotou uma velocidade relativamente maior na condição chuvosa. O desvio padrão reduziu (de 0,4802 para 0,4370), indicando uma menor dispersão dos valores. No *boxplot*, observa-se que a mediana se deslocou para valores menos negativos, e os *whiskers* também apresentam uma menor extensão na condição chuvosa, apontando uma condução mais uniforme.

Para o motorista F, a média e a mediana da velocidade aumentaram sob chuva, passando de -0,3730 para 0,0172 e de -0,3828 para -0,0818, respectivamente. Essa mudança indica que esse condutor dirigiu em velocidades superiores na condição chuvosa. O desvio padrão reduziu de 0,5324 para 0,2917, sugerindo uma menor dispersão nos valores. No *boxplot*, o deslocamento da mediana e a redução da amplitude dos *whiskers* confirmam que a condução sob chuva foi mais homogênea.

O motorista H também apresentou uma elevação na velocidade sob chuva, com a média passando de -0,3119 para -0,2256 e a mediana de -0,3212 para -0,2685. O desvio padrão reduziu de 0,3740 para 0,2901, indicando que a variabilidade da condução foi menor na condição chuvosa. O *boxplot* reforça esse comportamento, apresentando *whiskers* mais curtos e uma menor dispersão dos valores sob chuva.

O motorista I apresentou um comportamento oposto, com uma redução na velocidade sob chuva. A média reduziu de -0,4837 para -0,9642 e a mediana de -0,5435 para -0,9971, sugerindo que esse condutor adotou uma estratégia mais conservadora na presença de precipitação. O desvio padrão também diminuiu substancialmente de 0,4840 para 0,0454, indicando que a condução sob chuva foi mais homogênea e com menor variabilidade. No *boxplot*, a mediana se deslocou para valores mais negativos, e os *whiskers* ficaram mais curtos, evidenciando a restrição da velocidade sob chuva.

O motorista L reduziu a velocidade média de -0,4314 para -0,4866 e a mediana de -0,3829 para -0,4143 sob chuva. O desvio padrão também diminuiu de 0,4498 para 0,4084, sugerindo menor variabilidade na condução em condições adversas. O *boxplot* apresenta um deslocamento da mediana para valores mais negativos, e os *whiskers* apresentam menor amplitude, confirmando um padrão mais homogêneo na chuva.

O motorista M teve um aumento na velocidade média e mediana sob chuva, com a média subindo de -0,3407 para -0,2225 e a mediana de -0,2267 para -0,1548. O desvio padrão também reduziu de 0,5042 para 0,3934, indicando uma menor dispersão dos valores. O *boxplot* reflete essa tendência, com a mediana se deslocando para valores menos negativos e a redução na extensão dos *whiskers*, apontando uma condução mais previsível sob chuva.

O motorista N aumentou sua velocidade sob chuva, com a média passando de -0,4796 para -0,2424 e a mediana de -0,5138 para -0,2437. O desvio padrão permaneceu praticamente estável (0,4868 sem chuva e 0,4883 com chuva), indicando que a variabilidade da condução não foi significativamente afetada. O *boxplot* mostra uma mudança na posição da mediana para valores menos negativos sob chuva, acompanhada de uma redução na dispersão dos valores.

O motorista O apresentou um comportamento inverso, reduzindo a velocidade sob chuva, com a média passando de -0,2905 para -0,3285 e a mediana de -0,2559 para -0,2681. O desvio padrão também reduziu de 0,4786 para 0,4159, indicando menor variabilidade na condução. No *boxplot*, observa-se uma diminuição na extensão dos *whiskers* e uma posição mais negativa da mediana na condição chuvosa.

O motorista P apresentou uma redução mais acentuada na velocidade sob chuva, com a média passando de -0,4504 para -0,5789 e a mediana de -0,4296 para -0,8067. O desvio padrão aumentou de 0,4380 para 0,4794, indicando uma maior dispersão nos valores sob chuva. No *boxplot*, a mediana se deslocou significativamente para valores mais negativos, e os *whiskers* apresentam maior amplitude, sugerindo um padrão de condução mais variável sob chuva.

O motorista T reduziu a velocidade média e mediana sob chuva, com a média passando de -0,3019 para -0,4013 e a mediana de -0,2474 para -0,3672. O desvio padrão apresentou uma leve redução de 0,4909 para 0,4624, indicando uma condução ligeiramente mais homogênea sob chuva. No *boxplot*, observa-se um deslocamento da mediana para valores mais negativos e *whiskers* com menor amplitude, confirmando a tendência de redução da velocidade sob chuva.

O motorista X teve uma mudança significativa na velocidade sob chuva, com a média passando de -0,9825 para -0,8815 e a mediana de -1,0000 para -0,9960. O desvio padrão aumentou de 0,1073 para 0,3166, indicando uma maior variabilidade na condução sob chuva. No *boxplot*, essa mudança é evidenciada pelo alargamento da distribuição e pelo aumento na extensão dos *whiskers*, sugerindo um padrão de condução mais instável sob chuva.

O motorista Y apresentou um aumento na velocidade sob chuva, com a média passando de -0,3500 para -0,2538 e a mediana de -0,3213 para -0,1926. O desvio padrão reduziu ligeiramente de 0,5539 para 0,5429, indicando uma condução mais homogênea sob chuva. O *boxplot* mostra uma elevação da mediana e *whiskers* menos extensos, sugerindo menor dispersão dos valores.

O motorista Z apresentou uma leve redução na velocidade média e mediana sob chuva, com a média passando de -0,5966 para -0,6134 e a mediana de -0,8413 para -0,8098. O desvio padrão reduziu de 0,4695 para 0,4286, indicando uma menor dispersão nos valores sob chuva. No *boxplot*, observa-se que a mediana se manteve relativamente estável, mas com *whiskers* ligeiramente menores na condição chuvosa.

Após a análise da estatística descritiva e dos *boxplot*, conforme fluxograma apresentado na Figura 5.5, foram aplicados os testes de normalidade de D'Agostino-Pearson (tamanho amostral superior a 50 observações) ou de Shapiro-Wilk (amostra inferior a 50 observações) (Shapiro-Wilk ou D'Agostino-Pearson) para a velocidade nas condições de tempo límpido e chuvoso. Os resultados destes testes são mostrados na Tabela 6.29.

Tabela 6.29 Testes de Normalidade: Shapiro-Wilk ou D'Agostino-Pearson: Velocidade (com e sem chuva)

Motorista	Condição	Teste de Normalidade	p-valor
AC	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
AD	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0008 ¹
AE	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0002 ¹
D	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0009 ¹
F	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0000 ¹
H	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
I	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0003 ¹
L	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
M	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0008 ¹

N	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
O	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
P	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0003 ¹
T	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
X	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
Y	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
Z	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Observa-se que todos os valores de p , apresentados na Tabela 6.29, resultaram em rejeição da hipótese nula de normalidade ($p < 0,05$), o que indica que nenhuma das distribuições de velocidade apresentou aderência à distribuição normal, independentemente da condição climática ou do motorista analisado.

Em função dessa não normalidade, aplicou-se o teste não paramétrico U de Mann-Whitney para avaliar diferenças de velocidade entre as amostras. A Tabela 6.30 mostra os p-valores obtidos pela aplicação do referido teste, considerando as condições de tempo seco e chuvoso.

Tabela 6.30. Teste não paramétrico (U Mann-Whitney) aplicado às condições de chuva e sua ausência

Motorista	Amostra - Com Chuva (s)	Amostra - Sem Chuva (s)	U-Mann-Whitney p-valor
AC	94	488	0,0000 ¹
AD	31	1410	0,1993 ²
AE	1468	20135	0,0000 ¹
D	28	1191	0,3581 ²
F	40	19220	0,0000 ¹
H	1394	39255	0,0000 ¹
I	21	1153	0,0002 ¹
L	3758	37394	0,0000 ¹
M	1608	20868	0,0000 ¹
N	319	8850	0,0000 ¹
O	1772	30299	0,0095 ¹
P	135	3157	0,0001 ¹
T	3464	29013	0,0000 ¹
X	10375	39014	0,0000 ¹
Y	3479	10092	0,0000 ¹
Z	432	6705	0,4447 ²

¹Diferença significativa; ²Não há diferença significativa.

A Tabela 6.30 revela que, para a maioria dos motoristas (AC, AE, F, H, I, L, M, N, O, P, T, X e Y), os p-valores foram inferiores a 0,05. Isso indica diferenças estatisticamente

significativas entre as distribuições de velocidade nas condições de chuva e sem chuva. Esses motoristas demonstraram maior sensibilidade às mudanças climáticas, ajustando sua velocidade em resposta às condições adversas.

Esses resultados estão alinhados com estudos como o de Agarwal *et al.* (2006), que avaliaram os impactos das condições meteorológicas no desempenho operacional de segmentos rodoviários. Os autores constataram uma redução na velocidade de tráfego entre 1% e 7% durante períodos de chuva. Da mesma forma, Caleffi *et al.* (2016), ao analisar o comportamento do tráfego em um trecho da BR-290/RS na região metropolitana de Porto Alegre (RS), observaram uma redução média de 10 km/h na velocidade durante chuvas. Tais pesquisas reforçam a tendência observada no presente estudo, destacando que uma parcela dos motoristas adapta sua velocidade em resposta a condições climáticas adversas.

Além disso, a experiência e o comportamento individual dos motoristas podem influenciar a resposta às condições climáticas adversas. Motoristas mais experientes ou cautelosos tendem a reduzir a velocidade em situações de chuva, enquanto aqueles menos precavidos podem manter comportamentos semelhantes independentemente das condições. O estudo de Malhotra *et al.* (2018) investigou como a tendência de monitorar e controlar conscientemente decisões e ações (autorreflexão) influencia o comportamento ao volante. Utilizando questionários e testes em simuladores de direção com 51 participantes, os autores constataram que motoristas com alta propensão à autorreflexão tendem a dirigir mais devagar. Ademais, a experiência e as atitudes dos motoristas influenciaram a escolha da velocidade: condutores mais experientes e com atitudes positivas em relação à segurança reduziram sua velocidade, enquanto aqueles com atitudes negativas em relação ao excesso de velocidade mantiveram velocidades mais altas.

Entretanto, para os motoristas AD, D e Z, os p-valores obtidos foram superiores a 0,05, indicando que não houve diferença significativa na velocidade entre as condições de chuva e sem chuva. Essa ausência de ajuste na velocidade pode ser atribuída às características individuais desses motoristas, que parecem ser menos sensíveis às variações climáticas e, conseqüentemente, não alteram sua velocidade de forma significativa. Sundström (2011) reforça essa perspectiva ao destacar que muitos motoristas tendem a superestimar suas habilidades ao dirigir, acreditando-se mais competentes e seguros do que a média. Essa percepção equivocada pode levar à subestimação dos riscos associados a condições climáticas adversas, resultando em uma falta de adaptação adequada da velocidade, mesmo em situações que demandam maior cautela.

Diante do exposto, os resultados deste estudo destacam a importância de considerar as condições climáticas e as características individuais dos motoristas na análise do comportamento ao dirigir. Enquanto uma parcela de condutores demonstra maior sensibilidade e adaptação às condições adversas, outra parcela parece subestimar os riscos, mantendo velocidades inadequadas. Isso indica a necessidade de campanhas de conscientização e políticas públicas que incentivem a adoção de velocidades seguras em condições climáticas adversas, além de estratégias que promovam a autorreflexão e a conscientização sobre os riscos associados à direção em situações desfavoráveis.


Além da velocidade, foi analisada a aceleração, nas condições sem chuva e com chuva. A Tabela 6.31 apresenta a estatística descritiva desta variável.

Tabela 6.31. Estatística descritiva: aceleração (com chuva e sem chuva)

Motorista	Condição	Amostras (s)	Média (m/s²)	Mediana (m/s²)	Desvio Padrão (m/s²)
AC	Sem chuva	251	0,0323	0,0119	0,1242
	Com chuva	45	0,0543	0,0422	0,0431
AD	Sem chuva	687	0,0850	0,0219	0,2572
	Com chuva	15	0,0362	0,0250	0,0293
AE	Sem chuva	9694	0,4822	0,1772	1,4131
	Com chuva	638	0,3310	0,1931	0,4070
D	Sem chuva	388	0,0959	0,0447	0,1472
	Com chuva	11	0,0731	0,0447	0,0362
F	Sem chuva	9635	0,4386	0,2592	0,4916
	Com chuva	25	0,2468	0,2431	0,1582
H	Sem chuva	21162	0,2746	0,1844	0,2869
	Com chuva	751	0,2524	0,1753	0,2603
I	Sem chuva	568	0,3434	0,1208	0,4740
	Com chuva	11	0,1457	0,0692	0,2068
L	Sem chuva	18799	1,4883	0,9060	1,6145
	Com chuva	1866	1,2596	0,6885	1,4264
M	Sem chuva	10881	1,3496	0,8410	1,4976
	Com chuva	847	1,5859	1,0350	1,5602
N	Sem chuva	4503	1,5207	0,8600	1,7380
	Com chuva	160	1,8547	1,1100	1,9815
O	Sem chuva	15429	1,3655	0,8510	1,4903
	Com chuva	908	1,2041	0,7445	1,2901
P	Sem chuva	1571	1,5678	1,0630	1,6989
	Com chuva	61	1,4093	0,6420	1,5765
T	Sem chuva	15388	0,4180	0,2972	0,4094
	Com chuva	1866	0,4615	0,3482	0,4485
X	Sem chuva	8094	0,1076	0,0447	0,2150
	Com chuva	3210	0,1781	0,0447	0,2983
Y	Sem chuva	5664	1,3978	0,8175	1,5355
	Com chuva	1967	1,6671	1,2050	1,5447
Z	Sem chuva	3287	0,3191	0,1092	0,4322
	Com chuva	217	0,3873	0,1486	0,4835

Para complementar essa análise estatística descritiva, foi utilizada a representação gráfica por meio de *boxplots*, conforme ilustrado na Figura 6.6. O uso desse método permite a identificação de assimetria na distribuição dos dados, dispersão e presença de valores atípicos, além de viabilizar comparações diretas entre os períodos diurno e noturno. A interpretação conjunta dos resultados tabulares e gráficos contribui para uma compreensão mais detalhada das tendências observadas, auxiliando na verificação da hipótese levantada.

Figura 6.6 *Boxplot*: Aceleração de cada condutores (chuva e sem chuva)



A análise da Tabela 6.31 em conjunto com o *boxplot* apresentado na Figura 6.6 permite uma avaliação detalhada do comportamento da aceleração dos motoristas nas condições com e sem chuva. Para os motoristas AC e AD, observa-se que a média e a mediana da aceleração sob chuva apresentaram variações mínimas em relação à condição sem chuva. No caso do motorista AC, houve um leve aumento na média (de 0,0323 m/s² para 0,0543 m/s²) e na mediana (de 0,0119 m/s² para 0,0422 m/s²), acompanhado por uma redução no desvio padrão, indicando menor dispersão dos valores sob chuva. O *boxplot* confirma essa tendência ao apresentar *whiskers* mais curtos e menor presença de *outliers* na condição chuvosa. Para o motorista AD, os valores médios e medianos reduziram ligeiramente sob chuva, e o desvio padrão também diminuiu, sugerindo uma condução mais estável e previsível em condições adversas.

Os motoristas AE, F e H apresentaram uma redução significativa na média da aceleração sob chuva. Para AE, a média reduziu de 0,4822 m/s² para 0,3310 m/s² e a mediana aumentou de 0,1772 m/s² para 0,1931 m/s², enquanto o desvio padrão reduziu de 1,4131 m/s² para 0,4070 m/s², evidenciando menor variabilidade da aceleração sob chuva. O *boxplot* confirma essa estabilidade, com uma menor dispersão dos dados na condição chuvosa e uma diminuição na quantidade de *outliers*. O motorista F apresentou um comportamento similar, com a média reduzindo de 0,4386 m/s² para 0,2468 m/s² e a mediana se mantendo próxima, o que sugere que a chuva levou a uma aceleração menos intensa e mais homogênea. O motorista H, por sua vez, apresentou uma leve redução na média e na mediana sob chuva, com o desvio padrão reduzindo de 0,2869 m/s² para 0,2603 m/s². O *boxplot* mostra que, apesar de uma distribuição semelhante entre as condições, há menor dispersão e amplitude dos *whiskers* sob chuva, sugerindo uma menor variabilidade na condução.

O motorista I apresentou uma redução expressiva na aceleração média, que passou de 0,3434 m/s² para 0,1457 m/s², e a mediana também sofreu uma redução acentuada. O desvio padrão diminuiu, indicando que esse condutor adotou uma aceleração mais homogênea sob chuva. O *boxplot* evidencia essa mudança, com um deslocamento da mediana para valores menores e uma redução notável nos *whiskers*, apontando uma condução mais cautelosa sob condições adversas.

Os motoristas L, M, N e O apresentaram comportamentos distintos. L e O reduziram a aceleração sob chuva, com a média passando de 1,4883 m/s² para 1,2596 m/s² no caso de L, e de 1,3655 m/s² para 1,2041 m/s² para O. A redução na mediana e no desvio padrão também indica menor variabilidade na aceleração desses condutores sob chuva. Os *boxplots* refletem essa mudança, apresentando *whiskers* menos extensos e uma menor quantidade de *outliers* na

condição chuvosa. Por outro lado, os motoristas M e N aumentaram sua aceleração sob chuva, com a média de M subindo de $1,3496 \text{ m/s}^2$ para $1,5859 \text{ m/s}^2$ e a de N aumentando de $1,5207 \text{ m/s}^2$ para $1,8547 \text{ m/s}^2$. A mediana também aumentou, indicando que esses motoristas adotaram um comportamento mais dinâmico na condição chuvosa. O *boxplot* desses condutores apresenta maior dispersão e *whiskers* mais longos sob chuva, indicando maior variabilidade na aceleração.

O motorista P apresentou uma leve redução na aceleração média e na mediana sob chuva, com o desvio padrão se mantendo relativamente estável. No *boxplot*, observa-se que os *whiskers* são menos extensos sob chuva, sugerindo que esse motorista teve uma condução mais uniforme na presença de precipitação.

O motorista T apresentou aumento na aceleração média, na mediana sob chuva e no desvio padrão. O *boxplot* mostra um leve deslocamento da mediana para valores mais elevados e *whiskers* um pouco mais longos sob chuva, indicando uma maior variabilidade da aceleração em condições chuvosas.

O motorista X aumentou sua aceleração média e mediana sob chuva, com a média passando de $0,1076 \text{ m/s}^2$ para $0,1781 \text{ m/s}^2$. O desvio padrão aumentou de $0,2150 \text{ m/s}^2$ para $0,2983 \text{ m/s}^2$, indicando uma maior variabilidade na condução. O *boxplot* reflete esse comportamento, apresentando maior dispersão dos valores sob chuva e um número mais elevado de *outliers*.

Os motoristas Y e Z também apresentaram aumento na aceleração sob chuva, com a média de Y passando de $1,3978 \text{ m/s}^2$ para $1,6671 \text{ m/s}^2$ e a de Z de $0,3191 \text{ m/s}^2$ para $0,3873 \text{ m/s}^2$. O *boxplot* desses motoristas mostra um deslocamento da mediana para valores mais elevados e um aumento na dispersão dos dados sob chuva, indicando maior variabilidade na condução.

Do exposto, os resultados indicam que a chuva impactou a aceleração de forma heterogênea entre os condutores. Enquanto alguns reduziram a intensidade das acelerações, adotando um comportamento mais cauteloso, outros mantiveram ou até aumentaram suas acelerações, possivelmente ajustando sua condução de acordo com suas estratégias individuais. O *boxplot* confirma essas diferenças, evidenciando mudanças na posição da mediana, na dispersão dos valores e na presença de *outliers*, refletindo a diversidade de padrões de aceleração em condições climáticas adversas.

Conforme fluxograma mostrado na Figura 5.5, foram aplicados os testes de normalidade para a aceleração em condições de tempo límpido e chuvoso. Em função do tamanho amostral, adotou-se os testes de D'Agostino-Pearson (tamanho amostral superior a 50

observações) ou de Shapiro-Wilk (amostra inferior a 50 observações). A Tabela 6.32 apresenta esses resultados.

Tabela 6.32. Testes de normalidade para aceleração (com e sem chuva)

Motorista	Grupo	Teste de Normalidade	p-valor
AC	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0034 ¹
AD	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,1072 ²
AE	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
D	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0024 ¹
F	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,2595 ²
H	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
I	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0014 ¹
L	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
M	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
N	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
O	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
P	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0012 ¹
T	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
X	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
Y	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
Z	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Os resultados dos testes de normalidade, apresentados na Tabela 6.32 mostram que a maioria dos motoristas tanto na condição de chuva quanto sem chuva, obtiveram p-valores inferiores a 0,05, indicando que a hipótese de normalidade pode ser rejeitada. Entretanto, os motoristas AD e F, ambos sob chuva, apresentaram distribuição normal, com p-valores de 0,10720 e 0,25948, respectivamente.

Com base no fluxograma apresentado na Figura 5.5, após a verificação da normalidade, procedeu-se com a aplicação de testes não paramétricos. Assim, o teste de U Mann-Whitney foi aplicado para comparar as amostras. Os p-valores obtidos estão apresentados na Tabela 6.33.

Tabela 6.33. Teste não paramétrico (U Mann-Whitney) para aceleração (com chuva e sem chuva)

Motorista	Amostra Com Chuva (s)	Amostra Sem Chuva (s)	p-valor
AC	45	251	0,00000 ¹
AD	15	687	0,57206 ²
AE	638	9695	0,04429 ¹
D	11	388	0,92844 ²
F	25	9635	0,45203 ²
H	752	21310	0,21135 ²
I	11	568	0,23009 ²
L	1866	18820	0,00000 ¹
M	847	10993	0,00000 ¹
N	160	4503	0,01069 ¹
O	912	15458	0,01286 ¹
P	61	1571	0,21364 ²
T	1866	15470	0,00391 ¹
X	3210	8094	0,00000 ¹
Y	1971	5780	0,00000 ¹
Z	217	3287	0,08465 ²

¹Diferença significativa; ²Não há diferença significativa.

A análise do teste U de Mann-Whitney (Tabela 6.33) revela comportamentos distintos entre motoristas em relação à aceleração com e sem chuva. Para 9 motoristas (AC, AE, L, M, N, O, T, X e Y), p-valores inferiores a 0,05 indicam diferenças significativas nas distribuições de aceleração, sugerindo que ajustam seu comportamento em condições adversas (BILLOT *et al.*, 2009; Camacho *et al.*, 2010; e Hou *et al.*, 2013), possivelmente reduzindo a intensidade das acelerações para maior controle.

Por outro lado, 7 motoristas (AD, D, F, H, I, P e Z) apresentaram p-valores superiores a 0,05, mostrando que não adaptaram significativamente sua aceleração à chuva. Esse padrão pode estar ligado à menor sensibilidade às mudanças climáticas, superestimação das habilidades ou estilo de direção mais agressivo, conforme destacado por Edwards (1999) e Kilpeläinen e Summala (2007). Além disso, chuvas leves ou moderadas durante a coleta de dados podem não ter influenciado significativamente o comportamento desses condutores (Stamos *et al.*, 2016).

O comportamento dos motoristas que apresentaram distribuição não normal pode estar relacionado a características específicas de seu comportamento ao volante. Por exemplo, esses motoristas podem ter padrões de aceleração mais consistentes e previsíveis em condições adversas, resultando em uma distribuição mais próxima da normalidade. Isso pode refletir maior experiência, cautela ou até mesmo um estilo de direção mais controlado.

O tamanho da amostra sob chuva para os motoristas AD, F e I também pode ter influenciado os resultados dos testes de normalidade. O motorista AD, por exemplo, teve apenas 15 observações sob chuva, enquanto o motorista F teve 25 observações. Amostras menores podem ser mais suscetíveis a variações aleatórias, o que pode levar a resultados de normalidade mesmo quando a distribuição subjacente não é estritamente normal.

Além do exposto, as condições climáticas durante os períodos de coleta de dados para os motoristas AD e F podem ter sido menos severas, resultando em um comportamento de aceleração mais estável e próximo da normalidade. Chuvas leves ou moderadas podem não afetar significativamente o comportamento de aceleração, ao contrário de chuvas intensas ou tempestades (STAMOS *et al.*, 2016). Isto pode ter ocorrido também porque no município de Curitiba, as precipitações são abundantes durante todo o ano, fazendo com que estes condutores tenham costume de dirigir na chuva, não tomando medidas de cuidado adicionais. Segundo dados históricos, em Curitiba chove em média 189,3 dias ao ano (METEOBLUE, 2023). A subestimação do risco associado à precipitação também pode justificar esse comportamento (KILPELÄINEN e SUMMALA, 2007).

Esses resultados têm implicações para a segurança viária, pois motoristas que não ajustam a aceleração em condições adversas estão mais expostos a riscos de acidentes, especialmente em situações que exigem maior controle, como frenagens ou curvas. A falta de adaptação pode aumentar a probabilidade de colisões, comprometendo a segurança do condutor e de outros usuários da via. Portanto, é essencial promover campanhas de conscientização que enfatizem a importância de ajustar a aceleração e adotar práticas de direção defensiva em condições climáticas desfavoráveis.

Conforme a Teoria da Homeostase de Risco (Delhomme *et al.*, 2009), os motoristas ajustam seu comportamento para manter um nível constante de risco percebido, mas nem sempre eliminam o risco por completo. Campanhas educativas podem ajudar a reduzir o nível de risco aceitável, sensibilizando os condutores sobre os benefícios de comportamentos cautelosos e os custos de ações arriscadas, especialmente em situações adversas. Ao incentivar ajustes na aceleração e práticas defensivas, essas iniciativas podem contribuir para escolhas mais seguras e reduzir a probabilidade de acidentes.

Após a análise das distribuições de velocidade e aceleração, avaliou-se o comportamento do condutor quanto a frenagem em diferentes condições climáticas. A Tabela 6.34 apresenta estatísticas descritivas, como média, mediana e desvio padrão, permitindo a


comparação do comportamento de frenagem em situações de tempo chuvoso e seco. Essa abordagem possibilita identificar variações individuais na redução da velocidade e avaliar o impacto das condições meteorológicas sobre o processo de frenagem.

Tabela 6.34. Estatística descritiva: frenagem (chuva e sem chuva)

Motorista	Condições Meteorológicas	Amostras (s)	Média (m/s ²)	Mediana (m/s ²)	Desvio Padrão (m/s ²)
AC	Sem chuva	234	-0,0184	-0,0114	0,0228
	Com chuva	47	-0,0537	-0,0403	0,0431
AD	Sem chuva	694	-0,0600	-0,0200	0,2010
	Com chuva	14	-0,0366	-0,0246	0,0301
AE	Sem chuva	10406	-0,4428	-0,1747	1,2667
	Com chuva	827	-0,2824	-0,1833	0,3022
D	Sem chuva	393	-0,0918	-0,0447	0,1574
	Com chuva	8	-0,0950	-0,0671	0,0606
F	Sem chuva	9546	-0,4408	-0,2453	0,5315
	Com chuva	15	-0,2363	-0,2047	0,1421
H	Sem chuva	17777	-0,3321	-0,2103	0,4223
	Com chuva	638	-0,2645	-0,1963	0,2831
I	Sem chuva	579	-0,3541	-0,1422	0,4540
	Com chuva	10	-0,1943	-0,0404	0,2535
L	Sem chuva	18525	-1,5518	-0,8530	1,8414
	Com chuva	1887	-1,2616	-0,6910	1,5145
M	Sem chuva	9735	-1,5486	-0,7470	2,1046
	Com chuva	759	-1,8381	-1,0600	2,1583
N	Sem chuva	4339	-1,5883	-0,8230	1,9266
	Com chuva	159	-1,9370	-1,1640	2,0475
O	Sem chuva	14785	-1,4287	-0,8290	1,6132
	Com chuva	855	-1,2136	-0,7130	1,3273
P	Sem chuva	1576	-1,5607	-1,0375	1,7744
	Com chuva	74	-1,1043	-0,5375	1,5205
T	Sem chuva	13399	-0,4906	0-0,2617	0,5925
	Com chuva	1588	-0,5353	-0,2958	0,6224
X	Sem chuva	7718	-0,0751	-0,0447	0,1300
	Com chuva	3147	-0,1683	-0,0447	0,3131
Y	Sem chuva	4221	-1,9261	-0,5800	2,8276
	Com chuva	1503	-2,1512	-0,9460	2,8017
Z	Sem chuva	3382	-0,3050	-0,1106	0,4212
	Com chuva	215	-0,3847	-0,1564	0,5014

Para complementar essa análise estatística descritiva, foi utilizada a representação gráfica por meio de *boxplots*, conforme ilustrado na Figura 6.7. A interpretação conjunta dos resultados tabulares e gráficos contribui para uma compreensão mais detalhada das tendências observadas, auxiliando na verificação da hipótese levantada.

Figura 6.7. *Boxplot*: Frenagem de cada condutores (chuva e sem chuva)



Pela análise conjunta da Tabela 6.34 e da Figura 6.7, observa-se que para os motoristas AC e AD, sob chuva, houve um leve aumento na intensidade da frenagem, refletido pelo aumento na magnitude dos valores médios e medianos. No caso de AC, a média passou de $-0,0184 \text{ m/s}^2$ para $-0,0537 \text{ m/s}^2$, e a mediana de $-0,0114 \text{ m/s}^2$ para $-0,0403 \text{ m/s}^2$. O desvio padrão também aumentou, indicando maior dispersão dos valores sob chuva. O *boxplot* confirma essa tendência, evidenciando uma expansão dos *whiskers* e um aumento da presença de *outliers* sob chuva. Para AD, a média e a mediana apresentaram variações pequenas, mas o desvio padrão foi reduzido, sugerindo que esse motorista adotou um padrão de frenagem mais homogêneo na presença de chuva.

Os motoristas AE, F e H mostram uma redução na intensidade da frenagem sob chuva. Para AE, a média diminuiu de $-0,4428 \text{ m/s}^2$ para $-0,2824 \text{ m/s}^2$, enquanto a mediana se manteve relativamente estável. O desvio padrão reduziu consideravelmente, indicando menor variabilidade da frenagem. O *boxplot* reforça essa constatação, mostrando *whiskers* menos extensos e uma menor quantidade de *outliers* sob chuva. O motorista F apresentou um comportamento semelhante, com a média passando de $-0,4408 \text{ m/s}^2$ para $-0,2363 \text{ m/s}^2$ e a mediana se mantendo próxima. O motorista H também apresentou uma redução na média e na mediana sob chuva, e o desvio padrão diminuiu de $0,4223 \text{ m/s}^2$ para $0,2831 \text{ m/s}^2$. No *boxplot*, observa-se uma redução da dispersão dos valores e menor presença de *outliers* sob chuva, sugerindo uma frenagem mais controlada e previsível.

O motorista I apresentou mudança na distribuição da frenagem sob chuva. A média da frenagem passou de $-0,3541 \text{ m/s}^2$ para $-0,1943 \text{ m/s}^2$, e a mediana de $-0,1422 \text{ m/s}^2$ para $-0,0404 \text{ m/s}^2$. O desvio padrão reduziu, indicando uma menor variação na intensidade da frenagem. No *boxplot*, observa-se um encurtamento dos *whiskers* e uma menor quantidade de *outliers* na condição chuvosa, sugerindo uma condução mais homogênea nesse cenário.

Os motoristas L, M, N e O apresentaram padrões distintos. L e O reduziram a intensidade da frenagem sob chuva, com a média passando de $-1,5518 \text{ m/s}^2$ para $-1,2616 \text{ m/s}^2$ no caso de L, e de $-1,4287 \text{ m/s}^2$ para $-1,2136 \text{ m/s}^2$ para O. A mediana e o desvio padrão também diminuíram, indicando uma frenagem menos intensa e mais previsível sob chuva. O *boxplot* desses condutores confirma essa tendência, apresentando *whiskers* menos extensos e uma menor quantidade de *outliers* sob chuva. Por outro lado, os motoristas M e N aumentaram a intensidade da frenagem sob chuva, com a média de M reduzindo de $-1,5486 \text{ m/s}^2$ para $-1,8381 \text{ m/s}^2$ e a de N de $-1,5883 \text{ m/s}^2$ para $-1,9370 \text{ m/s}^2$. A mediana também se tornou mais negativa, indicando que esses motoristas realizaram frenagens mais bruscas sob chuva. O *boxplot* desses

condutores apresenta maior dispersão e *whiskers* mais longos sob chuva, indicando uma maior variabilidade na frenagem.

O motorista P apresentou uma redução na intensidade da frenagem sob chuva, com a média passando de $-1,5607 \text{ m/s}^2$ para $-1,1043 \text{ m/s}^2$ e a mediana de $-1,0375 \text{ m/s}^2$ para $-0,5375 \text{ m/s}^2$. O desvio padrão também foi reduzido, sugerindo que esse motorista freou de forma mais previsível sob chuva. No *boxplot*, observa-se *whiskers* menos extensos e uma menor quantidade de *outliers* na condição chuvosa.

O motorista T aumentou a intensidade da frenagem sob chuva, com a média passando de $-0,4906 \text{ m/s}^2$ para $-0,5353 \text{ m/s}^2$ e a mediana reduziu de $-0,2617 \text{ m/s}^2$ para $-0,2958 \text{ m/s}^2$. O desvio padrão aumentou, sugerindo maior variabilidade na frenagem. O *boxplot* mostra expansão dos *whiskers* sob chuva, indicando uma maior dispersão dos valores de frenagem.

O motorista X demonstrou alteração na frenagem sob chuva, com a média passando de $-0,0751 \text{ m/s}^2$ para $-0,1683 \text{ m/s}^2$ e o desvio padrão aumentando de $0,1300 \text{ m/s}^2$ para $0,3131 \text{ m/s}^2$. A mediana permaneceu inalterada, indicando que a maioria das frenagens ocorreu dentro de um mesmo padrão, mas com alguns eventos de frenagem mais brusca sob chuva. O *boxplot* reflete essa mudança, apresentando *whiskers* mais extensos e uma maior presença de *outliers*.

Os motoristas Y e Z também apresentaram aumento na intensidade da frenagem sob chuva. A média de Y reduziu de $-1,9261 \text{ m/s}^2$ para $-2,1512 \text{ m/s}^2$ e mediana de $-0,5800 \text{ m/s}^2$ para $-0,9460 \text{ m/s}^2$. O desvio padrão manteve-se relativamente estável, sugerindo que esse motorista adotou frenagens mais intensas, mas sem aumentar a variabilidade dos valores. O *boxplot* confirma essa tendência, mostrando uma distribuição mais negativa dos valores sob chuva. O motorista Z apresentou um comportamento semelhante, com a média reduzindo de $-0,3050 \text{ m/s}^2$ para $-0,3847 \text{ m/s}^2$ e a mediana passando de $-0,1106 \text{ m/s}^2$ para $-0,1564 \text{ m/s}^2$. O *boxplot* indica uma leve expansão da distribuição sob chuva, com *whiskers* um pouco mais extensos.

Do exposto, os resultados mostram que a resposta à chuva não é uniforme entre os motoristas, sendo influenciada por fatores como percepção de risco, experiência na condução em condições adversas e o tipo de via percorrida. Enquanto alguns condutores adotam uma abordagem mais prudente e homogênea, outros mantêm ou intensificam suas frenagens, possivelmente confiando em suas habilidades ou ajustando sua condução conforme as necessidades momentâneas. A predominância de motoristas que reduziram a variabilidade e adotaram desacelerações mais suaves reforça a tendência de adaptação conservadora diante da

precipitação, conforme indicado por estudos sobre comportamento viário em condições meteorológicas adversas.

Conforme fluxograma mostrado na Figura 5.5, foram aplicados os testes de normalidade para a frenagem em condições de tempo límpido e chuvoso. Em função do tamanho amostral, adotou-se os testes de D'Agostino-Pearson (tamanho amostral superior a 50 observações) ou de Shapiro-Wilk (amostra inferior a 50 observações). A Tabela 6.35 apresenta estes resultados.

Tabela 6.35. Teste de normalidade para frenagem (com e sem chuva)

Motorista	Condição	Teste de Normalidade	p-valor
AC	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0003 ¹
AD	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0855 ²
AE	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
D	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0178 ¹
F	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0155 ¹
H	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
I	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	Shapiro-Wilk	0,0043 ¹
L	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
M	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
N	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
O	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
P	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
T	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
X	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
Y	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹
Z	Sem chuva	D'Agostino-Pearson	0,0000 ¹
	Com chuva	D'Agostino-Pearson	0,0000 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Pela Tabela 6.35, observa-se que a maioria dos condutores apresentou não normalidade ($p < 0,05$). A predominância desse tipo de distribuição na maioria dos casos reforça a complexidade e a variabilidade do comportamento de frenagem, especialmente em condições

adversas, como a chuva. A presença de valores extremos ou a influência de fatores externos, como a aderência da pista e a percepção de risco, podem contribuir para essa não normalidade.

Todavia, o comportamento do motorista AD sob chuva, foi exceção. O teste de Shapiro-Wilk resultou em p-valor de 0,08548, não sendo possível rejeitar a hipótese de normalidade para esse conjunto de dados. Isso indica que em condições chuvosas, os dados de frenagem seguiram uma distribuição normal, o que pode estar relacionado a um comportamento mais consistente ou a uma menor variabilidade nas frenagens realizadas por esse condutor sob chuva. Insta salientar que a amostra avaliada para o motorista AD, na condição de chuva, contemplava somente 8 segundos de viagens, o que pode ter comprometido esse resultado.

Como houve predominância de distribuições não normais, aplicou-se o teste não paramétrico U Mann-Whitney para comparar as distribuições de frenagem entre as condições climáticas analisadas. Os resultados estão apresentados na Tabela 6.36.

Tabela 6.36. Teste não paramétrico (U Mann-Whitney) para frenagem (com e sem chuva)

Motorista	Amostra Com Chuva (s)	Amostra Sem Chuva (s)	p-valor
AC	47	234	0,00000 ¹
AD	14	694	0,44004 ²
AE	827	10410	0,09592 ²
D	8	393	0,41786 ²
F	15	9546	0,70003 ²
H	641	17907	0,06101 ²
I	10	579	0,35989 ²
L	1887	18529	0,00000 ¹
M	759	9830	0,00000 ¹
N	159	4339	0,00506 ¹
O	857	14809	0,01000 ¹
P	74	1576	0,00490 ¹
T	1588	13461	0,02565 ¹
X	3147	7718	0,00000 ¹
Y	1505	4294	0,00000 ¹
Z	215	3382	0,04444 ¹

¹Diferença significativa; ²Não há diferença significativa.

Os resultados apresentados na Tabela 6.36, obtidos por meio do teste não paramétrico U de Mann-Whitney, revelam diferenças significativas no comportamento de frenagem dos motoristas sob distintas condições climáticas. Para os motoristas AC, L, M, N, O, P, T, X, Y e Z, os p-valores inferiores a 0,05 evidenciam uma diferença estatisticamente significativa, indicando que as distribuições de frenagem variam de forma expressiva entre as condições climáticas analisadas. Isso sugere que esses motoristas ajustaram seu comportamento de frenagem em resposta às mudanças no clima, possivelmente devido a fatores como redução de

aderência do pavimento, visibilidade reduzida ou maior percepção de risco, conforme destacado por Edwards (1999) e corroborado por estudos como os de Elyoussoufi *et al.* (2023) e Faria *et al.* (2020).

No entanto, para os motoristas AD, AE, D, F, H e I, os p-valores superiores a 0,05 (0,44004, 0,09592, 0,41786, 0,70003, 0,06101 e 0,35989, respectivamente) indicam que não há diferenças estatisticamente significativas nas distribuições de frenagem entre as condições climáticas avaliadas. Nesses casos, não foi possível rejeitar a hipótese nula de igualdade entre as distribuições, evidenciando que esses motoristas não alteraram significativamente seu padrão de frenagem em função das variações climáticas. Essa ausência de diferença pode estar relacionada às características individuais, como maior experiência ao volante ou menor sensibilidade às condições externas, conforme discutido por Delhomme *et al.* (2009) em seu estudo sobre a variabilidade individual em resposta a estímulos externos.

As diferenças observadas nos resultados destacam a influência de fatores individuais no comportamento de frenagem, evidenciando que a resposta às condições climáticas varia entre os motoristas. Essa variabilidade tem implicações na segurança viária, reforçando a necessidade de políticas públicas e programas de treinamento que levem em conta a diversidade de perfis de condutores. Sakhare *et al.* (2023) e Ni *et al.* (2022) demonstram que a chuva afeta não apenas a velocidade dos veículos, mas também a distância mantida entre eles, o que ressalta a importância de estratégias específicas para mitigar riscos em condições adversas. Além disso, a redução do coeficiente de fricção da pista em superfícies molhadas, conforme documentado por Wang *et al.* (2021) e Kordani, Rahmani e Nasiri (2018), reforça a necessidade de observar esses aspectos no planejamento viário.

Esses resultados estão alinhados com pesquisas que apontam que, sob condições adversas, os condutores tendem a adotar estratégias de frenagem mais suaves para minimizar os riscos de derrapagem e perda de controle do veículo (Harré, 2000; Camacho *et al.*, 2010). No entanto, as variações entre os motoristas podem ser explicadas por uma combinação de fatores, como percepção de risco, experiência na condução e adaptação às condições variáveis da pista (Mayhew e Simpson, 1995; Kilpeläinen e Summala, 2007; Sundström, 2011).

Além da hipótese 4, cujo resultado foi apresentado anteriormente, para atingir os objetivos deste trabalho também foi testada a seguinte hipótese:

Hipótese 5: A combinação de precipitação e luminosidade, durante o dia e a noite afeta o desempenho individual do condutor em relação à velocidade, aceleração e frenagem?

Essa abordagem permite compreender o impacto do período da viagem (diurno ou noturno), sob chuva, no comportamento de cada motorista no que tange à velocidade, aceleração e frenagem. A amostra foi composta por apenas 3 motoristas que realizaram deslocamentos sob ambas as condições, com tempo de viagem superior a 5 segundos em todas as situações investigadas.


A Tabela 6.37 apresenta as estatísticas descritivas referentes à velocidade dos 4 condutores (AD, L, T e X), contemplando o tamanho da amostra (em segundos), além dos valores de médias, medianas e desvios padrão de velocidade.

Tabela 6.37. Estatística descritiva: velocidade individualizada (período diurno e noturno, sob chuva)

Motorista	Período	Amostras (s)	Média	Mediana	Desvio Padrão
L	Diurno	1735	-0,5122	-0,4761	0,4235
	Noturno	2023	-0,4646	-0,3794	0,3938
T	Diurno	1848	-0,2206	-0,1994	0,4434
	Noturno	1616	-0,6080	-0,6714	0,3918
X	Diurno	8451	-0,8580	-0,9960	0,3446
	Noturno	1924	-0,9846	-0,9973	0,0776

Para complementar essa análise estatística descritiva, foi utilizada a representação gráfica por meio de *boxplots*, conforme ilustrado na Figura 6.8. A interpretação conjunta dos resultados tabulares e gráficos contribui para uma compreensão mais detalhada das tendências observadas, auxiliando na verificação da hipótese levantada.

Figura 6.8 Boxplot: Velocidade de cada condutor (período diurno e noturno, sob chuva)



Pela análise conjunta da Tabela 6.37 e da Figura 6.8, observa-se que para o motorista L, sob chuva, os valores médios e medianos indicam que a velocidade relativa foi maior no período noturno em comparação ao diurno, com a média passando de -0,5122 para -0,4646 e a mediana de -0,4761 para -0,3794. O desvio padrão também foi menor no período noturno (0,3938 contra 0,4235 no diurno), sugerindo uma menor variabilidade da velocidade à noite. O *boxplot* confirma essa tendência, apresentando uma distribuição mais compacta no período noturno, com *whiskers* menos extensos e menor dispersão. A presença de *outliers* em ambos os períodos indica que houve variações pontuais na velocidade, mas a amplitude interquartil foi menor no período noturno, o que pode sugerir uma condução mais homogênea.

Diferentemente de L, o condutor T apresentou uma redução significativa na velocidade relativa no período noturno, mesmo ambas as condições ocorrendo sob chuva. A média passou de -0,2206 no diurno para -0,6080 no noturno, enquanto a mediana reduziu-se de -0,1994 para -0,6714, evidenciando que esse motorista reduziu consideravelmente a velocidade à noite. O desvio padrão foi ligeiramente menor no período noturno (0,3918 contra 0,4434 no diurno), sugerindo que a condução foi menos variável durante a noite. O *boxplot* confirma esse comportamento, indicando um deslocamento da distribuição para valores mais negativos no

período noturno. Além disso, os *whiskers* são mais alongados no diurno, refletindo maior variabilidade, enquanto no noturno há uma concentração maior dos valores próximos à mediana, indicando uma tendência de velocidade mais estável.

Para o motorista X, sob chuva, a velocidade relativa foi menor durante a noite, mesmo com a presença de chuva nos dois períodos analisados. A média passou de -0,8580 no diurno para -0,9846 no noturno, enquanto a mediana manteve-se praticamente estável (-0,9960 no diurno e -0,9973 no noturno). O desvio padrão, entretanto, foi consideravelmente reduzido no período noturno, passando de 0,3446 para 0,0776, o que indica que a variação da velocidade foi muito menor à noite. O *boxplot* reforça essa constatação, mostrando uma distribuição altamente concentrada em torno da mediana no noturno, com *whiskers* muito curtos e um menor número de *outliers*. Isso sugere que, durante a noite, esse motorista manteve um padrão de velocidade mais consistente, possivelmente devido à menor visibilidade e a um comportamento mais cauteloso.

Essa análise mostra que o período do dia parece influenciar no comportamento dos motoristas sob chuva, mas de maneira diferente entre os condutores. A resposta de cada motorista à visibilidade reduzida depende de fatores individuais, como a percepção subjetiva do risco e a familiaridade com a condução em condições adversas.

Após a análise da estatística descritiva e dos *Boxplot*, conforme fluxograma apresentado na Figura 5.5, foram aplicados os testes de normalidade de D'Agostino-Pearson (tamanho amostral superior a 50 observações) às velocidades registradas nos períodos diurno e noturno, ambos sob chuva. Os resultados desses testes estão apresentados na Tabela 6.38.

Tabela 6.38. Teste de normalidade para velocidades relativas (dia e noite, sob chuva)

Motorista	Período	Teste de Normalidade	p-valor
L	Diurno	D'Agostino-Pearson	0,00000 ¹
	Noturno	D'Agostino-Pearson	0,00000 ¹
T	Diurno	D'Agostino-Pearson	0,00000 ¹
	Noturno	D'Agostino-Pearson	0,00000 ¹
X	Diurno	D'Agostino-Pearson	0,00000 ¹
	Noturno	D'Agostino-Pearson	0,00000 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Pela Tabela 6.38, verifica-se que todas as velocidades relativas registradas nos períodos diurno e noturno não seguiram uma distribuição normal ($p < 0,05$).

Em função dessa não normalidade, aplicou-se o teste não paramétrico U de Mann-Whitney para comparação dos padrões de velocidade entre os períodos diurno e noturno, sob chuva. Os resultados do referido teste estão apresentados na Tabela 6.39.

Tabela 6.39. Teste não paramétrico para velocidades (U Mann-Whitney): dia e noite, sob chuva

Motorista	Amostra - Diurno (s)	Amostra - Noturno (s)	U Mann-Whitney p-valor
L	1735	2023	0,0003 ¹
T	1848	1616	0,0000 ¹
X	8451	1924	0,0000 ¹

¹Diferença significativa; ²Não há diferença significativa.

Conforme Tabela 6.39, a aplicação do teste U de Mann-Whitney revelou que, para todos os motoristas analisados (L, T e X), as diferenças na distribuição da velocidade entre os períodos diurno e noturno, sob chuva, foram estatisticamente significativas ($p < 0,05$). Esse resultado indica que os motoristas alteraram sua velocidade em resposta às variações de luminosidade, reforçando a hipótese de que a visibilidade influencia na condução sob condições climáticas adversas.

Para o motorista L, o p-valor de 0,0003 sugere que sua velocidade à noite diferiu significativamente da adotada durante o dia. Como evidenciado anteriormente, houve um pequeno aumento na velocidade média e mediana no período noturno. Isso indica que, apesar da redução da visibilidade, esse motorista não reduziu a velocidade de maneira expressiva, o que pode estar associado a uma menor percepção do risco ou à confiança na sua capacidade de adaptação à condição noturna. Esse comportamento é semelhante aos resultados encontrados por Kilpeläinen e Summala (2007), que indicam que alguns motoristas tendem a subestimar os riscos da condução em ambientes de baixa luminosidade.

No caso do motorista T, o p-valor de 0,0000 confirma que a diferença observada entre o dia e a noite é estatisticamente robusta. Esse condutor reduziu significativamente sua velocidade no período noturno, evidenciando um comportamento mais conservador e cauteloso em resposta à visibilidade reduzida. Esse padrão é consistente com as conclusões de Konstantopoulos *et al.* (2010), que apontam que a diminuição da iluminação noturna, associada à chuva, tende a impactar negativamente a eficácia da busca visual dos motoristas, levando a uma condução mais defensiva.

O motorista X também apresentou uma diferença estatisticamente significativa na velocidade entre os períodos analisados ($p = 0,0000$). Esse condutor dirigia em um patamar de velocidade reduzido durante o dia e, à noite, adotou um comportamento ainda mais conservador, apresentando uma menor variabilidade na velocidade e um desvio padrão reduzido. Esse comportamento é compatível com os estudos de Jägerbrand e Sjöbergh (2016), que demonstraram que, em condições de chuva e baixa visibilidade, motoristas mais cautelosos

não apenas reduzem sua velocidade, mas também passam a dirigir de forma mais homogênea, reduzindo oscilações bruscas na velocidade.

Os resultados obtidos reforçam que a iluminação e a visibilidade sob chuva influenciam significativamente a velocidade dos motoristas, mas de forma individualizada. A percepção do risco e a experiência prévia em condução noturna sob condições adversas são fatores determinantes na adaptação da velocidade. Assim, embora todos os motoristas tenham apresentado diferenças estatisticamente significativas entre o dia e a noite, os padrões de ajuste foram distintos, evidenciando a importância de considerar fatores comportamentais na análise do impacto da visibilidade no trânsito.


Após a análise das distribuições de velocidade, avaliou-se o comportamento dos condutores em relação à aceleração sob chuva, considerando os períodos diurno e noturno. A Tabela 6.40 apresenta estatísticas descritivas, como média, mediana e desvio padrão.

Tabela 6.40 Estatística descritiva para aceleração (dia e noite, sob chuva)

Motorista	Período	Amostra (s)	Média (m/s²)	Mediana (m/s²)	Desvio Padrão (m/s²)
L	Diurno	884	1,1671	0,6050	1,3616
	Noturno	987	1,3361	0,7710	1,4773
T	Diurno	1025	0,5660	0,4992	0,4358
	Noturno	851	0,3303	0,1336	0,4297
X	Diurno	5779	0,0880	0,0000	0,2280
	Noturno	1449	0,0438	0,0000	0,1652

Para complementar essa análise estatística descritiva, foi utilizada a representação gráfica por meio de *boxplots*, conforme ilustrado na Figura 6.9. A interpretação conjunta dos resultados tabulares e gráficos contribui para uma compreensão mais detalhada das tendências observadas, auxiliando na verificação da hipótese levantada.

Figura 6.9 Boxplot: Aceleração de cada condutor (dia e noite, sob chuva)



Pela análise conjunta da Tabela 6.40 e da Figura 6.9, observa-se que, para o condutor L houve um aumento na aceleração média e mediana no período noturno, passando de 1,1671 m/s^2 para 1,3361 m/s^2 na média e de 0,6050 m/s^2 para 0,7710 m/s^2 na mediana. O desvio padrão também aumentou no noturno (1,4773 m/s^2 contra 1,3616 m/s^2 no diurno), sugerindo uma maior variabilidade no padrão de aceleração à noite. O *boxplot* confirma essa tendência, mostrando uma distribuição mais elevada dos valores de aceleração no período noturno, com uma mediana deslocada para cima e *whiskers* mais longos, indicando uma maior amplitude de variação. Além disso, observa-se um maior número de *outliers* no noturno, o que reforça a hipótese de que esse condutor adotou um padrão de aceleração mais agressivo durante esse período.

O condutor T, sob chuva, apresentou uma redução expressiva na aceleração no período noturno. A média reduziu de 0,5660 m/s^2 no diurno para 0,3303 m/s^2 no noturno, enquanto a mediana passou de 0,4992 m/s^2 para 0,1336 m/s^2 . O desvio padrão manteve-se relativamente próximo entre os períodos (0,4358 m/s^2 no diurno e 0,4297 m/s^2 no noturno), indicando que a variabilidade da aceleração não sofreu alterações significativas. O *boxplot* evidencia essa redução, com uma distribuição mais concentrada e uma mediana significativamente menor no período noturno. Além disso, os *whiskers* estão mais curtos à noite, sugerindo uma menor

amplitude de variação, e há uma redução na presença de *outliers*, o que pode indicar uma condução mais estável e previsível nesse período.

O motorista X apresentou os menores valores de aceleração entre os condutores analisados. A média foi reduzida de 0,0880 m/s² no diurno para 0,0438 m/s² no noturno, enquanto a mediana permaneceu 0,0000 m/s² em ambos os períodos, sugerindo um padrão de condução predominantemente estável e com poucas variações. O desvio padrão também foi menor à noite (0,1652 m/s² contra 0,2280 m/s² no diurno), reforçando a ideia de que esse motorista teve um comportamento de aceleração mais homogêneo no período noturno. O *boxplot* corrobora essa tendência, mostrando uma distribuição altamente concentrada ao redor da mediana no noturno, com *whiskers* reduzidos e um menor número de *outliers*, indicando menor variabilidade na aceleração.

Assim, os resultados indicam que o impacto da visibilidade noturna na aceleração varia conforme o perfil do motorista. Enquanto alguns condutores compensam a baixa luminosidade com acelerações mais intensas, outros adotam uma abordagem mais cautelosa, reduzindo sua variabilidade de aceleração. Essa heterogeneidade indica que a percepção subjetiva do risco e a experiência individual podem ser determinantes no ajuste do comportamento sob condições de iluminação reduzida e chuva.

Para verificar estatisticamente essa relação, seguindo o fluxograma da Figura 5.5, foram aplicados testes de normalidade (Shapiro-Wilk ou D'Agostino-Pearson) às acelerações registradas sob chuva nos períodos diurno e noturno. Os resultados desses testes estão apresentados na Tabela 6.41.

Tabela 6.41 Teste de normalidade para aceleração (dia e noite, sob chuva)

Motorista	Período	Teste de Normalidade	p-valor
L	Diurno	D'Agostino-Pearson	0,00000 ¹
	Noturno	D'Agostino-Pearson	0,00000 ¹
T	Diurno	D'Agostino-Pearson	0,00000 ¹
	Noturno	D'Agostino-Pearson	0,00000 ¹
X	Diurno	D'Agostino-Pearson	0,00000 ¹
	Noturno	D'Agostino-Pearson	0,00000 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Pela Tabela 6.41, observa-se que, na maioria dos casos, as acelerações nos períodos diurno e noturno não seguiram uma distribuição normal ($p < 0,05$).

Devido as distribuições não normais, aplicou-se o teste não paramétrico de U de Mann-Whitney para a comparação dos padrões de aceleração entre os períodos diurno e noturno sob chuva. Os resultados encontram-se na Tabela 6.42.

Tabela 6.42 Teste não paramétrico (U de Mann-Whitney) para aceleração: diurno e noturno, sob chuva

Motorista	Amostra (Diurno)	Amostra (Noturno)	U de Mann-Whitney p-valor
L	884	987	0,00326 ¹
T	1025	851	0,00000 ¹
X	5779	1449	0,00000 ¹

¹Diferença significativa; ²Não há diferença significativa.

A aplicação do teste não paramétrico U de Mann-Whitney para comparação dos padrões de aceleração entre os períodos diurno e noturno sob chuva revelou diferenças estatisticamente significativas para todos os motoristas analisados, conforme apresentado na Tabela 6.42. Os p-valores foram menores que 0,05 para L, T e X. Isso indica que a distribuição da aceleração variou de maneira significativa entre os períodos analisados.

Para o motorista L, o teste apresentou um p-valor de 0,00326, evidenciando uma diferença estatisticamente significativa entre os períodos diurno e noturno. Esse resultado reforça a análise descritiva e do *boxplot*, que mostraram maior dispersão e intensidade das acelerações no período noturno. A elevação dos valores médios e da mediana noturna sugere que esse condutor pode ter adotado uma estratégia compensatória diante da menor visibilidade, intensificando as acelerações para ajustar a velocidade em função das variações de iluminação e percepção da via. Estudos como os de Konstantopoulos *et al.* (2010) indicam que motoristas com maior experiência podem manter padrões de aceleração mais intensos em condições de visibilidade reduzida devido a uma adaptação do tempo de reação e da busca visual.

No caso do motorista T, a diferença foi altamente significativa ($p < 0,00001$), reforçando a mudança substancial no seu comportamento entre os períodos diurno e noturno. A redução dos valores médios e da mediana no período noturno já havia sido observada na análise da estatística descritiva, e o teste não paramétrico U de Mann-Whitney confirma que essa diminuição não ocorreu por acaso, mas sim por um ajuste sistemático do condutor. Esse resultado corrobora estudos como os de Jägerbrand e Sjöbergh (2016), que apontam uma redução na variabilidade de aceleração em condições noturnas, associada à maior precaução diante da menor visibilidade e percepção reduzida dos riscos.

Para o motorista X, o p-valor também foi inferior a 0,00001, confirmando que a variação observada entre os períodos diurno e noturno é estatisticamente relevante. Embora esse

motorista tenha apresentado menores valores médios de aceleração em ambos os períodos, a análise estatística demonstra que sua condução noturna foi ainda mais conservadora, com redução significativa na frequência e intensidade das acelerações. O *boxplot* mostrou uma menor dispersão e presença de poucos *outliers* nesse período, sugerindo um comportamento mais estável. Esse resultado é consistente com a literatura, como os estudos de Rakha *et al.* (2008), que apontam que motoristas mais cautelosos tendem a reduzir ainda mais suas acelerações sob visibilidade reduzida, minimizando variações bruscas de velocidade e mantendo maior controle sobre o veículo.

Dessa forma, os resultados do teste U de Mann-Whitney validam estatisticamente a hipótese de que há diferenças significativas no padrão de aceleração dos motoristas entre os períodos diurno e noturno sob chuva, reforçando que a iluminação e a visibilidade são fatores determinantes no comportamento da condução. A resposta individual dos condutores, no entanto, varia conforme o perfil de cada motorista, evidenciando que a adaptação à menor visibilidade não é uniforme, mas sim influenciada por experiência, percepção de risco e estratégias individuais de direção.


Após a análise das velocidades e acelerações avaliou-se também o comportamento dos condutores em relação as frenagens nos períodos diurno e noturno, ambos sob chuva. A Tabela 6.43 apresenta as estatísticas descritivas, como médias, medianas e desvios padrões, para a situação investigada.

Tabela 6.43 Estatística descritiva: frenagem (dia e noite, sob chuva)

Motorista	Período	Amostra (s)	Média (m/s ²)	Mediana (m/s ²)	Desvio Padrão (m/s ²)
L	Diurno	851	-117,702	-0,583	149,320
	Noturno	1036	-133,112	-0,7585	152,894
T	Diurno	823	-0,70546	-0,45083	0,69597
	Noturno	765	-0,3522	-0,14944	0,46764
X	Diurno	2672	-0,18524	-0,0447	0,33229
	Noturno	475	-0,0727	-0,0447	0,13237

A Figura 6.10 apresenta, por meio de *Boxplots*, a distribuição dos dados de frenagens nos períodos diurno e noturno, sob chuva.

Figura 6.10 Boxplot: Frenagem de cada condutores (dia e noite, sob chuva)



Pela análise combinada da Figura 6.10 com os resultados da estatística descritiva (Tabela 6.43), pode-se observar que o condutor L apresentou uma maior intensidade de frenagem no período noturno, evidenciada pela redução da média de -117,702 m/s^2 no diurno para -133,112 m/s^2 no noturno. A mediana também seguiu essa tendência, passando de -0,583 m/s^2 no diurno para -0,7585 m/s^2 no noturno, indicando que, na maior parte do tempo, as frenagens foram mais intensas à noite. O desvio padrão aumentou no período noturno (152,894 m/s^2 contra 149,320 m/s^2 no diurno), sugerindo uma maior dispersão dos valores de frenagem. O *boxplot* corrobora essa observação, mostrando um deslocamento da mediana para valores mais negativos no noturno, além de *whiskers* mais longos e um maior número de *outliers*, indicando a ocorrência de frenagens mais bruscas e variadas durante esse período.

O condutor T reduziu significativamente a intensidade das frenagens no período noturno. A média passou de -0,70546 m/s^2 no diurno para -0,3522 m/s^2 no noturno, enquanto a mediana foi de -0,45083 m/s^2 para -0,14944 m/s^2 , indicando uma tendência de frenagem menos intensa à noite. O desvio padrão também diminuiu no noturno (0,46764 m/s^2 contra 0,69597 m/s^2 no diurno), sugerindo uma menor variabilidade na força de frenagem. O *boxplot* confirma esse padrão, evidenciando um deslocamento da mediana para valores menos negativos no

noturno, além de *whiskers* mais curtos e uma menor dispersão dos valores de frenagem, indicando que esse motorista adotou um comportamento mais estável à noite.

O condutor X apresentou os menores valores de frenagem entre os analisados. A média da desaceleração passou de $-0,18524 \text{ m/s}^2$ no diurno para $-0,0727 \text{ m/s}^2$ no noturno, enquanto a mediana permaneceu $-0,0447 \text{ m/s}^2$ em ambos os períodos, indicando que a maior parte das frenagens se manteve em um nível reduzido. O desvio padrão também foi menor no noturno ($0,13237 \text{ m/s}^2$ contra $0,33229 \text{ m/s}^2$ no diurno), sugerindo uma menor variabilidade na intensidade das frenagens durante a noite. O *boxplot* reforça essa conclusão, com *whiskers* mais curtos e uma menor dispersão dos valores no noturno, além de uma redução no número de *outliers*, o que indica um comportamento de frenagem mais controlado e homogêneo.

Do exposto, os *boxplots* e a estatística descritiva mostra que a iluminação e a visibilidade parecem influenciar o comportamento de frenagem dos motoristas de maneiras distintas. Enquanto o motorista L demonstrou maior variabilidade e intensidade nas frenagens noturnas, sugerindo dificuldades de adaptação às condições de menor visibilidade, os motoristas T e X adotaram estratégias mais estáveis, com reduções na dispersão e na intensidade das frenagens à noite.

De acordo com o fluxograma da Figura 5.5, foram aplicados testes de normalidade (Shapiro-Wilk ou D'Agostino-Pearson, conforme tamanho da amostra) às frenagens registradas sob chuva nos períodos diurno e noturno. Os resultados desses testes estão apresentados na Tabela 6.44.

Tabela 6.44 Teste de normalidade: Shapiro-Wilk ou D'Agostino-Pearson (dia e noite, sob chuva)

Motorista	Período	Teste de Normalidade	p-valor
L	Diurno	D'Agostino-Pearson	0,0000 ¹
	Noturno	D'Agostino-Pearson	0,0000 ¹
T	Diurno	D'Agostino-Pearson	0,0000 ¹
	Noturno	D'Agostino-Pearson	0,0000 ¹
X	Diurno	D'Agostino-Pearson	0,0000 ¹
	Noturno	D'Agostino-Pearson	0,0000 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Pela Tabela 6.44, observa-se que as frenagens não seguiram uma distribuição normal ($p < 0,05$). Devido a essas distribuições não normais, aplicou-se o teste não paramétrico de U-Mann-Whitney para comparar os padrões de frenagem entre os períodos diurno e noturno. Os resultados estão apresentados na Tabela 6.45.

Tabela 6.45 Teste não paramétrico (U Mann-Whitney) para frenagem: dia e noite, sob chuva

Motorista	Amostra -Diurno (s)	Amostra – Noturno (s)	U Mann-Whitney p-valor
L	851	1036	0,0011 ¹
T	823	765	0,0000 ¹
X	2672	475	0,0000 ¹

¹Diferença significativa; ²Não há diferença significativa.

A análise dos resultados do teste U de Mann-Whitney, apresentados na Tabela 6.45, indicou que houve diferenças estatisticamente significativas nos padrões de frenagem entre os períodos diurno e noturno para todos os motoristas analisados (L, T e X), uma vez que os p-valores encontrados foram inferiores a 0,05 ($p = 0,0011$, $0,0000$ e $0,0000$, respectivamente). Essa diferença sugere que a luminosidade e a consequente visibilidade influenciaram o comportamento de frenagem dos condutores sob chuva.

Para o motorista L, a diferença estatística observada reflete o padrão previamente identificado nos *boxplots* e nas estatísticas descritivas. No período noturno, a mediana das frenagens foi mais negativa, indicando uma tendência a desacelerações mais intensas, com maior dispersão dos valores e presença de *outliers* negativos. Isso sugere que, sob baixa luminosidade, este condutor adotou frenagens mais bruscas, possivelmente como estratégia para compensar a redução na visibilidade da via. Esse comportamento está alinhado com os resultados encontrados por Konstantopoulos *et al.* (2010), que demonstraram que motoristas tendem a ter tempos de reação mais longos e a depender de ações corretivas mais abruptas à noite.

O motorista T apresentou um comportamento distinto. A estatística descritiva e o *boxplot* indicaram que, durante a noite, suas frenagens foram menos intensas e mais homogêneas, o que pode estar relacionado a uma condução mais preventiva sob condições de baixa visibilidade. O teste de U de Mann-Whitney confirmou essa diferença significativa, indicando que o período da viagem influenciou na estratégia adotada para desaceleração. Estudos como os de Jägerbrand e Sjöbergh (2016) sugerem que motoristas que adotam um estilo de condução mais conservador à noite tendem a reduzir a velocidade média, minimizando a necessidade de frenagens bruscas.

O teste também apontou diferenças estatisticamente significativas entre os períodos diurno e noturno para o motorista X, mas o padrão de frenagem foi mais estável em comparação com os demais condutores. Durante a noite, observou-se menor dispersão e redução na intensidade das frenagens, o que pode estar associado a uma estratégia de condução mais suave

e regular. Conforme apontado por Rakha *et al.* (2009), condutores que apresentam menor variação nos padrões de frenagem tendem a manter velocidades mais constantes e ajustar a condução de forma gradativa, reduzindo a necessidade de ações abruptas.

Diante desses resultados, confirma-se que a luminosidade e a visibilidade influenciaram significativamente o comportamento de frenagem dos motoristas sob chuva, mas de maneiras distintas para cada condutor. Enquanto alguns motoristas adotaram estratégias mais cautelosas à noite, reduzindo a intensidade das frenagens, outros demonstraram reações mais abruptas, possivelmente em resposta à menor percepção do ambiente viário. Esses resultados reforçam a importância da adaptação do comportamento de condução às condições de baixa luminosidade e visibilidade reduzida, conforme discutido por Ghasemzadeh e Ahmed (2017), que demonstraram que motoristas são mais propensos a apresentar desvios de faixa e frenagens abruptas sob chuva intensa e baixa iluminação.

Além das hipóteses 4 e 5, cujos resultados foram apresentados anteriormente, para atingir os objetivos deste trabalho também foi testada a seguinte hipótese:

Hipótese 6: A combinação de precipitação e o fluxo de veículos em diferentes horários, incluindo os picos de tráfego, afeta o desempenho individual do condutor em relação à velocidade, aceleração e frenagem?

Para a análise dessa hipótese, investigou-se a variação de velocidade, aceleração e frenagem de forma individualizada, considerando a interação entre chuva e períodos de Pico e entre picos. A amostra foi composta apenas por 4 motoristas que realizaram deslocamentos sob ambos os períodos na condição chuvosa.

A Tabela 6.46 apresenta as estatísticas descritivas referentes à velocidade nos períodos de picos e entre picos para cada motorista avaliado. São fornecidas informações sobre o tamanho da amostra (em segundos), além da média, mediana e o desvio padrão dos valores de velocidade.

Tabela 6.46 Estatísticas descritivas de velocidade (picos e entre picos, sob chuva)

Motorista	Grupo	Amostra (s)	Média	Mediana	Desvio Padrão
H	Pico	733	-0,1694	-0,2723	0,3651
	Entre Picos	661	-0,2685	-0,2399	0,2939
L	Pico	1735	-0,5122	-0,4761	0,4235
	Entre Picos	2023	-0,4646	-0,3794	0,3938
T	Pico	881	-0,5858	-0,7058	0,4378
	Entre Picos	2583	-0,3384	-0,3231	0,4537
X	Pico	58	-0,9309	-0,9946	0,1515
	Entre Picos	10317	-0,8812	-0,9960	0,3173

Para complementar essa análise estatística descritiva, foi utilizada a representação gráfica por meio de *boxplots*, conforme ilustrado na Figura 6.11. A interpretação conjunta dos resultados tabulares e gráficos contribui para uma compreensão mais detalhada das tendências observadas, auxiliando na verificação da hipótese levantada.

Figura 6.11 Boxplot: Velocidade de cada condutor (pico e entre pico, sob chuva)



Pela análise combinada da Tabela 6.46 e da Figura 6.11, observa-se que o condutor H apresentou uma velocidade relativa inferior no período entre picos em comparação ao período de pico. A média passou de -0,1694 no pico para -0,2685 no entre picos, sugerindo uma redução na velocidade quando o fluxo de veículos foi menor. A mediana, por outro lado, apresentou uma elevação no período de entre picos (-0,2399) em relação ao pico (-0,2723), indicando que, apesar da redução média, a maior parte dos registros manteve-se relativamente próxima entre os períodos. O desvio padrão foi menor no período de entre picos (0,2939 contra 0,3651 no pico), indicando uma condução mais homogênea quando havia menor densidade de tráfego. O *boxplot* confirma essa observação, evidenciando uma menor dispersão dos valores no período entre picos e uma leve redução na quantidade de *outliers*, sugerindo que o motorista ajustou sua velocidade de maneira mais previsível fora dos horários de pico.

O motorista L apresentou um comportamento oposto ao de H, com um aumento na velocidade relativa no período de entre picos. A média passou de -0,5122 no pico para -0,4646 no entre picos, e a mediana também aumentou de -0,4761 para -0,3794, indicando que, no período de menor fluxo, esse condutor adotou um ritmo mais veloz. O desvio padrão também reduziu no entre picos (0,3938 contra 0,4235 no pico), sugerindo uma condução mais estável em momentos de menor densidade veicular. No *boxplot*, nota-se que a mediana no período de entre picos está menos negativa, enquanto no período de pico há uma maior dispersão dos valores e presença de *outliers* mais distantes, indicando que, sob tráfego intenso, esse motorista enfrentou maiores oscilações na velocidade, possivelmente devido à necessidade de adaptação ao fluxo da via.

O condutor T reduziu sua velocidade durante os horários de pico. A média passou de -0,5858 no pico para -0,3384 no entre picos, enquanto a mediana variou de -0,7058 para -0,3231, evidenciando que, nos períodos de maior fluxo, esse condutor teve sua velocidade restringida. O desvio padrão permaneceu semelhante entre os períodos (0,4537 no período de entre picos e 0,4378 no pico), sugerindo que, apesar da diferença na velocidade média, a dispersão dos valores foi relativamente constante. O *boxplot* ilustra essa tendência, com a mediana no período de entre picos deslocando-se para valores menos negativos e uma maior dispersão no período de pico, o que pode indicar que a densidade do tráfego impôs restrições mais significativas à condução desse motorista nos horários de maior movimentação.

O condutor X manteve velocidades reduzidas em ambos os períodos, com uma elevação na média no período de entre picos (-0,8812 contra -0,9309 no pico). No entanto, a mediana permaneceu praticamente inalterada (-0,9960 entre picos e -0,9946 no pico), indicando que, apesar de pequenas variações na média, a maior parte dos registros de velocidade manteve-se em um intervalo semelhante nos dois períodos. O desvio padrão aumentou no período de entre picos (0,3173 contra 0,1515 no pico), sugerindo uma condução menos homogênea quando o tráfego estava mais fluido. O *boxplot* confirma esse padrão, mostrando uma distribuição mais dispersa dos valores no período entre picos e um número expressivo de *outliers*, indicando que esse motorista pode ter adotado um comportamento mais variado quando não estava restrito pelo tráfego.

A análise combinada da estatística descritiva e do *boxplot* sugerem que a interação entre tráfego e chuva pode influenciar de forma distinta cada motorista. Para verificar tal relação, de acordo com o fluxograma metodológico apresentado na Figura 5.5, aplicou-se testes de normalidade (Shapiro-Wilk ou D'Agostino-Pearson) para verificar se as velocidades

relativas seguem distribuição normal nos períodos de pico e entre picos, sob chuva. Os resultados são apresentados na Tabela 6.47.

Tabela 6.47 Teste de normalidade para velocidades relativas (picos e entre picos, sob chuva)

Motorista	Período	Teste de Normalidade	p-valor
H	Pico	D'Agostino-Pearson	0,0000 ¹
	Entre Picos	D'Agostino-Pearson	0,0132 ¹
L	Pico	D'Agostino-Pearson	0,0000 ¹
	Entre Picos	D'Agostino-Pearson	0,0000 ¹
T	Pico	D'Agostino-Pearson	0,0000 ¹
	Entre Picos	D'Agostino-Pearson	0,0000 ¹
X	Pico	D'Agostino-Pearson	0,0000 ¹
	Entre Picos	D'Agostino-Pearson	0,0000 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Na Tabela 6.47, observa-se que, para todos os motoristas, as velocidades relativas nos períodos de pico e entre picos, ambos sob chuva, não seguiram uma distribuição normal ($p < 0,05$). Como houve distribuições não normais, aplicou-se teste não paramétrico de U de Mann-Whitney. Os resultados desse teste estão apresentados na Tabela 6.48.

Tabela 6.48 Teste não paramétrico para velocidades (U Mann-Whitney): picos e entre picos, sob chuva

Motorista	Amostra - Picos (s)	Amostra - Entre Picos (s)	U Mann-Whitney p-valor
H	733	661	0,0017 ¹
L	1735	2023	0,0003 ¹
T	881	2583	0,0000 ¹
X	58	10317	0,0027 ¹

¹Diferença significativa; ²Não há diferença significativa.

A análise dos resultados do teste não paramétrico de U de Mann-Whitney, apresentados na Tabela 6.48, evidencia que houve diferenças estatisticamente significativas nos valores de velocidade relativa entre os períodos de pico e entre picos, sob chuva, para todos os motoristas analisados (H, L, T e X). O fato de os p-valores serem inferiores a 0,05 para todos os condutores indica que a variação do fluxo de tráfego influenciou o comportamento dos motoristas, reforçando a hipótese de que o volume veicular e a precipitação afetam a velocidade sob condições climáticas adversas.

Para o motorista H, o teste revelou uma diferença estatisticamente significativa ($p = 0,0017$), sugerindo que o volume de tráfego impactou sua condução de forma considerável. Esse resultado é semelhante ao observado por Stern *et al.* (2003), que demonstraram que, durante os períodos de pico, os tempos de viagem aumentam, restringindo a liberdade do condutor para escolher sua velocidade. Além disso, Rakha *et al.* (2008) apontaram que o

comportamento do condutor é fortemente influenciado pela fluidez do tráfego, especialmente sob condições de chuva, uma vez que a visibilidade reduzida e o risco de aquaplanagem obrigam os motoristas a ajustarem sua velocidade em função do fluxo veicular.

No caso do condutor L, o teste U de Mann-Whitney indicou uma diferença significativa entre os períodos analisados ($p = 0,0003$), confirmando que a alteração na densidade veicular impactou sua velocidade relativa. Esse resultado pode estar associado à necessidade de frequentes ajustes na velocidade no período de pico, conforme evidenciado pelos *bootstrap* mais alongados e maior dispersão de valores no *boxplot* analisado anteriormente. Esse comportamento foi discutido por Song *et al.* (2023), que destacaram que, em vias congestionadas, motoristas frequentemente realizam pequenas variações de velocidade para se adaptar às condições do tráfego, o que pode resultar em uma condução menos estável. Além disso, Hassan *et al.* (2014) indicaram que, mesmo em condições climáticas adversas, alguns motoristas podem não reduzir a velocidade de maneira proporcional à densidade veicular, o que pode gerar maior variabilidade no comportamento de condução.

Para o motorista T, a diferença estatística altamente significativa ($p < 0,0001$) sugere que o fluxo de tráfego durante o pico influenciou na sua liberdade para conduzir em velocidades mais elevadas, o que se refletiu na redução expressiva da velocidade relativa observada na estatística descritiva e no *boxplot*. Esse resultado está alinhado com os estudos de Essien *et al.* (2018), que identificaram que, nos períodos de tráfego intenso, os motoristas tendem a reduzir a velocidade, independentemente das condições climáticas. Além disso, Elyousoufi *et al.* (2023) demonstraram que a interação entre chuva e tráfego intenso reduz a visibilidade e aumenta o risco de aquaplanagem, exigindo maior atenção e menor variabilidade na condução. Dessa forma, a redução da velocidade de T pode ter sido uma estratégia compensatória para lidar com a densidade veicular elevada e as condições adversas da via.

O motorista X, que apresentou uma amostra consideravelmente menor no período de pico ($n = 58$) em comparação ao período entre picos ($n = 10.317$), também teve uma diferença estatisticamente significativa ($p = 0,0027$). Esse resultado pode estar relacionado à variação na dispersão da velocidade observada na estatística descritiva e no *boxplot*, que indicou uma maior amplitude de valores no período entre picos. Segundo Jägerbrand e Sjöbergh (2016), motoristas podem apresentar maior variação na velocidade quando o tráfego é menos intenso, pois há maior liberdade para ajustes individuais no comportamento de condução. Adicionalmente, Agarwal *et al.* (2006) apontaram que a chuva influencia a capacidade viária, reduzindo a velocidade média dos condutores, especialmente em segmentos com maior densidade de tráfego. No caso de X, a combinação de fluxo veicular mais intenso e chuva pode ter restringido

sua variabilidade de condução, forçando-o a adotar um padrão mais controlado no período de pico.

Dessa forma, os resultados do teste U de Mann-Whitney confirmam que a variação do fluxo de veículos entre os períodos de pico e entre picos, sob chuva, impactou significativamente a velocidade dos condutores analisados. A literatura reforça que, em períodos de maior densidade veicular, a necessidade de ajustes frequentes na velocidade pode gerar um padrão de condução menos variável e mais restrito, enquanto períodos com menor fluxo permitem maior flexibilidade na escolha da velocidade (Stern *et al.*, 2003; Song *et al.*, 2023). Além disso, a interação entre a chuva e o tráfego intenso potencializa as dificuldades na percepção da via e aumenta o tempo de resposta dos motoristas, exigindo adaptações na condução que variam de acordo com a percepção de risco e a experiência individual de cada condutor (Hassan *et al.*, 2014; Ni *et al.*, 2022).


Além da velocidade, analisou-se a aceleração dos motoristas sob chuva nos períodos de pico e entre picos. A Tabela 6.49 apresenta as estatísticas descritivas, como média, mediana e desvio padrão, para cada condutor avaliado.

Tabela 6.49 Estatísticas descritivas de aceleração (picos e entre picos, sob chuva)

Motorista	Grupo	N (s)	Média (m/s ²)	Mediana (m/s ²)	Desvio Padrão (m/s ²)
H	Pico	415	0,2132	0,1294	0,2401
	Entre Picos	338	0,2992	0,2331	0,2762
L	Pico	884	1,1671	0,6050	1,3616
	Entre Picos	987	1,3361	0,7710	1,4773
T	Pico	459	0,3609	0,1422	0,4535
	Entre Picos	1417	0,4909	0,3914	0,4425
X	Pico	40	0,1375	0,0447	0,2165
	Entre Picos	7188	0,0788	0,0000	0,2176

Para complementar essa análise estatística descritiva, foi utilizada a representação gráfica por meio de *boxplots*, conforme ilustrado na Figura 6.12. A interpretação conjunta dos resultados tabulares e gráficos contribui para uma compreensão mais detalhada das tendências observadas, auxiliando na verificação da hipótese levantada.

Figura 6.12 Boxplot: Aceleração de cada condutor (picos e entre picos, sob chuva)



A análise combinada da Tabela 6.49 e da Figura 6.12 permite constatar que a aceleração média do condutor H foi maior no período de entre picos ($0,2992 \text{ m/s}^2$) em comparação ao pico ($0,2132 \text{ m/s}^2$), indicando que, em momentos de menor tráfego, esse condutor acelerou de forma mais intensa. A mediana também aumentou de $0,1294 \text{ m/s}^2$ no pico para $0,2331 \text{ m/s}^2$ no entre picos, sugerindo que a maior parte dos registros de aceleração foi superior quando havia menor densidade veicular. O desvio padrão foi superior no período de entre picos ($0,2762 \text{ m/s}^2$ contra $0,2401 \text{ m/s}^2$ no pico), indicando uma maior variabilidade nos valores de aceleração nesse período. No *boxplot*, observa-se uma elevação da mediana no entre picos, bem como uma dispersão ligeiramente maior dos valores, o que confirma a tendência de maior intensidade e variação nas acelerações quando o tráfego estava mais fluido.

Para o motorista L, a aceleração média foi maior no período de entre picos ($1,3361 \text{ m/s}^2$) em relação ao pico ($1,1671 \text{ m/s}^2$), evidenciando um padrão de aceleração mais intenso quando havia menor densidade de tráfego. A mediana aumentou de $0,6050 \text{ m/s}^2$ no pico para $0,7710 \text{ m/s}^2$ no entre picos, indicando que a maior parte das acelerações foi mais elevada no período com menor volume veicular. O desvio padrão também foi maior no período de entre picos ($1,4773 \text{ m/s}^2$ contra $1,3616 \text{ m/s}^2$ no pico), sugerindo uma condução mais dinâmica e menos previsível fora do horário de maior fluxo. O *boxplot* confirma essa análise, apresentando uma

mediana mais elevada no entre picos e uma maior dispersão dos valores de aceleração, com um aumento significativo na quantidade de *outliers*, o que indica que esse condutor realizou acelerações mais bruscas e variadas no período de menor tráfego.

O condutor T também apresentou acelerações mais elevadas no período de entre picos, com a média aumentando de 0,3609 m/s² no pico para 0,4909 m/s² no entre picos. A mediana variou de 0,1422 m/s² no pico para 0,3914 m/s² no entre picos, indicando que a maior parte das acelerações foi mais intensa quando havia menor fluxo de veículos. O desvio padrão permaneceu relativamente estável entre os períodos (0,4535 m/s² no pico e 0,4425 m/s² no entre picos), sugerindo que, embora as acelerações tenham sido mais fortes no entre picos, a variabilidade do comportamento de condução se manteve semelhante. Pelo *boxplot*, observa-se que a mediana se desloca para valores mais elevados no período de entre picos, enquanto no pico há uma distribuição mais concentrada, indicando que esse condutor acelerou de maneira mais uniforme sob tráfego intenso e de forma mais dispersa quando havia maior liberdade na via.

O condutor X apresentou uma redução na aceleração média no período de entre picos (0,0788 m/s²) em relação ao pico (0,1375 m/s²), sugerindo um padrão de condução mais cauteloso quando havia menor tráfego. A mediana no período de entre picos foi 0,0000 m/s², indicando que, na maior parte do tempo, esse motorista manteve a velocidade constante, sem realizar grandes acelerações. O desvio padrão foi superior no período de entre picos (0,2176 m/s² contra 0,2165 m/s² no pico), o que pode indicar que, apesar de manter um padrão mais estável, houve momentos de variação pontual nas acelerações. O *boxplot* confirma esse comportamento, mostrando uma distribuição mais concentrada no entre picos, com menor dispersão e uma mediana próxima de zero, reforçando a hipótese de que esse condutor evitou acelerações bruscas fora do horário de pico.

A análise combinada do *boxplot* e da estatística descritiva sugerem que o volume de tráfego influencia o comportamento de aceleração dos motoristas nos períodos de picos e entre picos, ambos sob chuva. Para verificar estatisticamente essa relação, seguindo o fluxograma da Figura 5.5, foram aplicados testes de normalidade (Shapiro-Wilk ou D'Agostino-Pearson, conforme tamanho da amostra). Os resultados desses testes estão apresentados na Tabela 6.50.

Tabela 6.50 Teste de normalidade para aceleração (picos e entre picos, sob chuva)

Motorista	Grupo	Teste de Normalidade	p-valor
H	Pico	D'Agostino-Pearson	0,0000 ¹
	Entre Picos	D'Agostino-Pearson	0,0000 ¹
L	Pico	D'Agostino-Pearson	0,0000 ¹

T	Entre Picos	D'Agostino-Pearson	0,0000 ¹
	Pico	D'Agostino-Pearson	0,0000 ¹
X	Entre Picos	D'Agostino-Pearson	0,0000 ¹
	Pico	Shapiro-Wilk	0,0000 ¹
	Entre Picos	D'Agostino-Pearson	0,0000 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Os resultados apresentados na Tabela 6.50 mostram que as acelerações para todos os motoristas seguiram uma distribuição não normal ($p < 0,05$). Em razão da não normalidade, aplicou-se o teste não paramétrico de U de Mann-Whitney para comparar pico e entre picos, sob chuva. A Tabela 6.51 apresenta os resultados obtidos a partir da aplicação do referido teste.

Tabela 6.51. Teste não paramétrico (U de Mann-Whitney) para aceleração: picos e entre picos, sob chuva

Motorista	Amostra (Pico)	Amostra Entre Picos	U de Mann-Whitney p-valor
H	415	338	0,0000 ¹
L	884	987	0,0033 ¹
T	459	1417	0,0000 ¹
X	40	7188	0,0003 ¹

¹Diferença significativa; ²Não há diferença significativa.

Pela Tabela 6.51 observa-se que para todos os motoristas analisados - H, L, T e X, o p-valor foi inferior a 0,05, indicando diferenças estatisticamente significativas entre as distribuições de aceleração nos períodos de pico e entre picos, sob chuva.

Para o motorista H, o teste apontou uma diferença estatisticamente significativa ($p = 0,0000$) entre os períodos de pico e entre picos, indicando que a aceleração foi distinta nesses momentos. Conforme observado na estatística descritiva e no *boxplot*, o período de entre picos apresentou valores médios e medianos de aceleração superiores, o que sugere que esse motorista ajustou sua condução conforme a densidade do tráfego. Esse comportamento é consistente com estudos que demonstram que menor volume de tráfego permite maior variação na aceleração, pois há menos restrições impostas pelo fluxo veicular (Essien *et al.*, 2018; Hassan *et al.*, 2014). Além disso, segundo Konstantopoulos *et al.* (2010), motoristas podem aumentar suas acelerações em ambientes de menor congestionamento devido à percepção reduzida de risco.

O condutor L também apresentou diferença estatisticamente significativa entre os períodos analisados ($p = 0,0033$), com acelerações mais intensas no entre picos, conforme indicado pela estatística descritiva. O *boxplot* evidenciou maior dispersão da aceleração nesse período, com a presença de vários *outliers*, reforçando a tendência de acelerações mais bruscas quando há maior liberdade para trafegar. Essa variação pode ser explicada pelo fato de que, durante os horários de pico, a alta densidade veicular limita a possibilidade de acelerações

intensas, conforme apontado por Rakha *et al.* (2009). Além disso, a presença de um fluxo de tráfego mais dinâmico pode ter levado esse condutor a realizar retomadas de velocidade mais abruptas no período de entre picos, um fenômeno observado em pesquisas que analisam o impacto da fluidez do tráfego sobre o comportamento de aceleração (Ni *et al.*, 2022).

A maior diferença estatística foi observada para o motorista T ($p = 0,0000$), reforçando que sua condução foi altamente influenciada pelo volume de tráfego. No período de pico, as acelerações foram significativamente menores e menos dispersas, indicando que esse condutor teve menos oportunidades para variar sua velocidade devido ao congestionamento. Esse comportamento é coerente com estudos que mostram que, em períodos de maior densidade viária, os motoristas precisam manter uma condução mais uniforme, reduzindo acelerações bruscas e mudanças abruptas de velocidade (Rakha *et al.*, 2009; Ferraz *et al.*, 2012; Sakhare *et al.*, 2023). No entre picos, no entanto, a aceleração média e a mediana aumentaram, sugerindo que o condutor se beneficiou da menor presença de veículos na via para adotar um comportamento de condução mais dinâmico.

Para o motorista X, mesmo observando acelerações menores quando comparado aos demais condutores, a diferença estatística também foi significativa ($p = 0,0003$). A estatística descritiva mostrou que a mediana da aceleração foi praticamente zero nos dois períodos, o que indica que esse motorista adotou um perfil de condução mais estável e uniforme, independentemente da densidade do tráfego. No entanto, a menor dispersão e a redução na presença de *outliers* no período de entre picos sugerem que o condutor manteve um padrão ainda mais previsível nesse período, o que está alinhado com os apontamentos de Rakha *et al.* (2008), que demonstraram que motoristas mais cautelosos tendem a minimizar variações bruscas na aceleração quando há menor interferência do tráfego.

Os resultados do teste U de Mann-Whitney reforçam que o volume de tráfego influencia o comportamento de aceleração dos motoristas sob chuva. Nesse sentido, vários estudos demonstram que a densidade veicular limita a liberdade dos condutores para alterar suas velocidades, reduzindo a variabilidade da aceleração e resultando em padrões de condução mais homogêneos (Rakha *et al.*, 2009; Sakhare *et al.*, 2023; Ferraz *et al.*, 2012). Essa relação é ainda mais evidente sob chuva, pois as condições adversas da pista aumentam a necessidade de ajustes na aceleração para garantir maior estabilidade do veículo (Jägerbrand e Sjöbergh, 2016; Ghasemzadeh e Ahmed, 2017).

Ademais, os diferentes padrões de aceleração observados entre os motoristas sugerem que fatores individuais, como percepção de risco e experiência na condução, interferem na adaptação ao tráfego e às condições meteorológicas (Kilpeläinen e Summala, 2007). Enquanto alguns condutores aproveitaram a menor densidade viária para intensificar suas acelerações, outros mantiveram uma condução mais uniforme, minimizando variações bruscas e possíveis riscos associados à pista molhada.


Esse estudo também avaliou o comportamento dos condutores em termos de frenagem nos períodos de pico e entre picos, sob chuva. A Tabela 6.52 apresenta a média, mediana e desvio padrão dos valores de frenagem para cada motorista.

Tabela 6.52 Estatísticas descritivas de frenagem (picos e entre picos, sob chuva)

Motorista	Período	Amostra (s)	Média (m/s ²)	Mediana (m/s ²)	Desvio Padrão (m/s ²)
H	Pico	318	-0,2054	-0,1438	0,1825
	Entre Picos	323	-0,3215	-0,2361	0,3455
L	Pico	851	-1,1770	-0,5830	1,4932
	Entre Picos	1036	-1,3311	-0,7585	1,5289
T	Pico	422	-0,3839	-0,1564	0,4662
	Entre Picos	1166	-0,5901	-0,3283	0,6617
X	Pico	18	-0,0633	-0,0447	0,0449
	Entre Picos	3129	-0,1689	-0,0447	0,3138

Para complementar essa análise estatística descritiva, foi utilizada a representação gráfica por meio de *boxplots*, conforme ilustrado na Figura 6.16. A interpretação conjunta dos resultados tabulares e gráficos contribui para uma compreensão mais detalhada das tendências observadas, auxiliando na verificação da hipótese levantada.

Figura 6.16. Boxplot: Frenagem de cada condutores (pico e entre pico, sob chuva)



A análise combinada da Tabela 6.52 e do *boxplot* da Figura 6.16 permite constatar que o condutor H apresentou uma frenagem média mais intensa no período de entre picos ($-0,3215 \text{ m/s}^2$) do que no pico ($-0,2054 \text{ m/s}^2$), indicando que as desacelerações foram mais intensas em momentos de menor tráfego. A mediana também se tornou mais negativa no período de entre picos ($-0,2361 \text{ m/s}^2$ contra $-0,1438 \text{ m/s}^2$ no pico), sugerindo que a maioria das frenagens foi mais intensa nesse período. O desvio padrão foi maior no período de entre picos ($0,3455 \text{ m/s}^2$ contra $0,1825 \text{ m/s}^2$ no pico), indicando maior variabilidade no padrão de frenagem. Pelo *boxplot*, observa-se uma dispersão maior das frenagens no período de entre picos, com uma mediana mais deslocada para valores negativos, reforçando a hipótese de que esse condutor adotou uma frenagem mais intensa e menos uniforme quando havia menor densidade veicular.

Para o motorista L, a média da frenagem foi mais negativa no período de entre picos ($-1,3311 \text{ m/s}^2$) em relação ao pico ($-1,1770 \text{ m/s}^2$), indicando que as desacelerações foram mais intensas quando havia menor volume de tráfego. A mediana seguiu a mesma tendência, sendo mais negativa no entre picos ($-0,7585 \text{ m/s}^2$ contra $-0,5830 \text{ m/s}^2$ no pico), o que sugere que, na maior parte do tempo, as frenagens foram mais fortes no período de menor tráfego. O desvio padrão foi maior no período de entre picos ($1,5289 \text{ m/s}^2$ contra $1,4932 \text{ m/s}^2$ no pico), indicando que esse condutor teve uma variabilidade mais ampla nos valores de frenagem quando a via

estava menos congestionada. O *boxplot* confirma essas observações, apresentando uma mediana mais negativa no entre picos, além de uma maior dispersão dos valores e um número maior de *outliers*, reforçando a ocorrência de desacelerações mais bruscas nesse período.

O condutor T também apresentou uma maior intensidade de frenagem no entre picos, com a média passando de $-0,3839 \text{ m/s}^2$ no pico para $-0,5901 \text{ m/s}^2$ no entre picos. A mediana seguiu essa tendência, reduzindo-se de $-0,1564 \text{ m/s}^2$ no pico para $-0,3283 \text{ m/s}^2$ no período de entre picos, o que indica que a maioria das frenagens foi mais intensa quando o tráfego estava mais fluido. O desvio padrão também foi maior no entre picos ($0,6617 \text{ m/s}^2$ contra $0,4662 \text{ m/s}^2$ no pico), sugerindo que, nesse período, o condutor apresentou maior variabilidade em suas frenagens. O *boxplot* confirma essas observações, mostrando uma mediana mais negativa no entre picos, além de uma maior dispersão dos dados e presença de *outliers*, o que indica uma condução menos previsível e com maior intensidade de frenagem quando havia menor densidade de tráfego.

O motorista X apresentou uma variação menos expressiva entre os períodos analisados. A média da frenagem foi um pouco mais negativa no período de entre picos ($-0,1689 \text{ m/s}^2$) em relação ao pico ($-0,0633 \text{ m/s}^2$), mas a mediana permaneceu praticamente constante em $-0,0447 \text{ m/s}^2$ nos dois períodos. O desvio padrão aumentou no período de entre picos ($0,3138 \text{ m/s}^2$ contra $0,0449 \text{ m/s}^2$ no pico), sugerindo que, embora a intensidade média da frenagem não tenha se alterado significativamente, houve uma maior variabilidade no comportamento do condutor nesse período. O *boxplot* reforça essa análise, mostrando uma mediana estável, mas um alongamento dos *whiskers* e um maior número de *outliers* no entre picos, indicando que esse motorista apresentou algumas frenagens mais bruscas nesse período, mesmo que sua estratégia geral de desaceleração tenha permanecido semelhante entre os períodos analisados.

Do exposto, observa-se que a intensidade das frenagens parece variar conforme o volume de tráfego, sendo mais acentuadas nos períodos de entre picos. Para verificar tal situação, seguindo o fluxograma da Figura 5.5, aplicou-se os testes de normalidade (Shapiro-Wilk ou D'Agostino-Pearson, conforme tamanho da amostra) para as frenagens registradas sob chuva nos períodos de pico e entre picos. A Tabela 6.53 apresenta os resultados obtidos.

Tabela 6.53 Teste de normalidade: Shapiro-Wilk ou D'Agostino-Pearson (picos e entre picos, sob chuva)

Motorista	Período	Teste de Normalidade	p-valor
H	Pico	D'Agostino-Pearson	0,0000 ¹
	Entre Picos	D'Agostino-Pearson	0,0000 ¹
L	Pico	D'Agostino-Pearson	0,0000 ¹
	Entre Picos	D'Agostino-Pearson	0,0000 ¹

T	Pico	D'Agostino-Pearson	0,0000 ¹
	Entre Picos	D'Agostino-Pearson	0,0000 ¹
X	Pico	Shapiro-Wilk	0,0000 ¹
	Entre Picos	D'Agostino-Pearson	0,0000 ¹

¹ Distribuição Não Normal; ² Distribuição Normal.

Pelos resultados apresentados na Tabela 6.53, constata-se que as frenagens não seguiram uma distribuição normal ($p < 0,05$). Devido a essas distribuições não normais, aplicou-se o teste U de Mann-Whitney para verificar diferenças significativas entre os períodos investigados. A Tabela 6.54 apresenta os resultados do teste U de Mann-Whitney para a comparação das frenagens nos períodos de pico e entre picos para cada motorista.

Tabela 6.54 Teste não paramétrico (U Mann-Whitney) :pico e entre picos, sob chuva

Motorista	Amostra -Pico (s)	Amostra- Entre Picos (s)	U Mann-Whitney p-valor
H	318	323	0,0000 ¹
L	851	1036	0,0011 ¹
T	422	1166	0,0000 ¹
X	18	3129	0,1396 ²

¹Diferença significativa; ²Não há diferença significativa.

A aplicação do teste não paramétrico U de Mann-Whitney para a comparação dos padrões de frenagem nos períodos de pico e entre picos sob chuva revelou diferenças estatisticamente significativas para os motoristas H, L e T (p -valor inferior a 0,05), conforme apresentado na Tabela 6.54. Apenas para o motorista X, a diferença entre os períodos analisados não foi estatisticamente significativa ($p = 0,1396$). Esses resultados indicam que o volume de tráfego influenciou significativamente o comportamento de frenagem da maioria dos motoristas, reforçando a hipótese de que a combinação entre fluxo veicular e condições climáticas afeta a condução.

Para o motorista H, a frenagem apresentou diferença significativa entre os períodos analisados (p -valor = 0,0000), confirmando a tendência observada na estatística descritiva e no *boxplot*. Durante o período de entre picos, os valores médios e medianos foram mais negativos, e o desvio padrão aumentou, sugerindo frenagens mais intensas e variáveis. Esse comportamento pode ser explicado pela menor densidade de tráfego, que permite maior liberdade para variações de velocidade e, conseqüentemente, para frenagens mais bruscas. Segundo Jägerbrand e Sjöbergh (2016), em condições de tráfego livre, os motoristas têm maior flexibilidade para ajustar sua velocidade, mas podem não antecipar corretamente obstáculos ou mudanças na via, resultando em desacelerações mais abruptas. Além disso, Ferraz *et al.* (2012)

destacam que a interação entre fatores humanos e ambientais pode agravar a variabilidade da frenagem, especialmente sob condições de visibilidade reduzida pela chuva.

O motorista L também apresentou diferenças estatisticamente significativas entre os períodos analisados (p -valor = 0,0011), confirmando que sua estratégia de frenagem foi influenciada pelo fluxo veicular. O deslocamento da mediana para valores mais negativos no período de entre picos sugere que, com menor volume de tráfego, esse condutor realizou frenagens mais intensas e variáveis. Esse resultado é semelhante aos apontados por Rakha *et al.* (2009), que demonstraram que motoristas tendem a adotar uma condução menos homogênea quando há menor interferência de outros veículos. Além disso, Kordani, Rahmani e Nasiri (2018) mostraram que a distância de frenagem pode aumentar significativamente sob chuva intensa, exigindo ajustes bruscos no comportamento do condutor para compensar a menor aderência da pista.

Para o motorista T, a diferença entre os períodos foi significativa (p -valor= 0,0000), indicando uma adaptação do comportamento de frenagem conforme o fluxo veicular. A análise da estatística descritiva e do *boxplot* revelou que, no período de pico, as frenagens foram menos intensas e mais homogêneas, enquanto no entre picos houve aumento na intensidade e na dispersão dos valores de desaceleração. Esse comportamento pode estar associado à necessidade de realizar frenagens mais controladas no tráfego congestionado, evitando colisões com veículos à frente. Conforme Rahman e Lownes (2012), motoristas tendem a frear de maneira mais progressiva em situações de tráfego intenso para evitar impactos sucessivos, enquanto em vias mais livres podem realizar desacelerações abruptas. Além disso, Ni *et al.* (2022) indicam que motoristas ajustam sua condução de forma distinta conforme as condições da via e do tráfego, o que pode explicar a maior variabilidade observada no entre picos.

Diferentemente dos demais motoristas, X não apresentou diferença estatisticamente significativa ($p = 0,1396$) entre os períodos de pico e entre picos, indicando que seu padrão de frenagem permaneceu estável independentemente do fluxo de tráfego. Esse resultado pode ser explicado pelo fato de que esse condutor pode não ter percorrido vias que sofreram impacto considerável do aumento do tráfego na hora de pico, o que teria minimizado a necessidade de ajustes na frenagem. Conforme apontado por Rakha *et al.* (2009), a influência do tráfego no comportamento dos motoristas depende do tipo de via percorrida: em vias arteriais ou rodovias de grande fluxo, a variação no volume de tráfego tende a impactar consideravelmente a condução, enquanto em vias locais e secundárias essa influência pode ser menos expressiva.

Além disso, a análise da estatística descritiva e do *boxplot* mostrou que X apresentou uma condução mais homogênea e defensiva, com valores de frenagem menos variáveis em ambos os períodos. Essa constatação está alinhada com estudos como os de Ghasemzadeh e Ahmed (2017), que indicam que motoristas com estilos de condução mais conservadores mantêm um padrão mais previsível de frenagem, independentemente das mudanças no fluxo de tráfego. Esse comportamento pode ser influenciado por fatores individuais, como experiência na condução sob chuva, percepção de risco e escolha de rotas menos afetadas pelo congestionamento (Kilpeläinen e Summala, 2007).

Do exposto, os resultados do teste U de Mann-Whitney mostram haver influência do volume de tráfego na intensidade e variabilidade das frenagens sob chuva, mas demonstram que essa relação não se manifesta de maneira uniforme entre todos os motoristas. Para H, L e T, a presença ou ausência de congestionamento afetou significativamente a maneira como a desaceleração foi conduzida, enquanto para X, o comportamento de frenagem permaneceu constante, possivelmente devido ao tipo de via percorrida e ao seu estilo de condução.

7. CONCLUSÕES

Este estudo investigou o impacto da precipitação no comportamento dos condutores em ambiente urbano, considerando variáveis como velocidade, aceleração e frenagem, além da influência da luminosidade e do fluxo de tráfego. Para isso, utilizou-se uma metodologia baseada em estudos naturalísticos de direção, permitindo a coleta de dados reais sem interferência externa. A combinação dos registros dos veículos com dados meteorológicos possibilitou uma análise detalhada das mudanças no comportamento dos motoristas sob diferentes condições ambientais. Além disso, a aplicação do *bootstrap* BCa aprimorou a confiabilidade estatística dos resultados, identificando diferenças significativas não detectadas na amostra original.

O desenvolvimento da pesquisa foi estruturado em sete etapas: (i) aprovação no Comitê de Ética em Pesquisa (CEP), garantindo a adequação ética do estudo; (ii) coleta de dados em condições reais de tráfego, por meio de sensores instalados em veículos; (iii) conversão das trajetórias para o sistema UTM, permitindo a integração espacial; (iv) combinação das bases meteorológica e de condução; (v) classificação das viagens em condições com chuva e sem chuva; (vi) segmentação em subviagens conforme as mudanças nas condições climáticas; e (vii) classificação das subviagens sob chuva segundo os períodos de luminosidade (diurno/noturno) e de fluxo de tráfego (pico/entre picos).

Metodologicamente, houve uma distinção entre as hipóteses globais (1, 2 e 3) e as individualizadas (4, 5 e 6). As primeiras analisaram o comportamento dos condutores de forma global, comparando os dados de toda a amostra entre as condições com e sem chuva e; diurno e noturno, sob chuva; e pico e entre pico, sob chuva.

As hipóteses cujas análise foram individualizadas analisaram o comportamento de cada motorista separadamente, considerando variações específicas de velocidade, aceleração e frenagem. Essa diferenciação metodológica possibilitou uma análise mais detalhada dos impactos da chuva, tanto em um nível global, identificando tendências gerais, quanto em um nível individualizado, permitindo avaliar diferenças comportamentais entre os condutores.

A Hipótese 1 investigou a porcentagem de tempo de permanência dos motoristas em diferentes faixas de velocidade, aceleração e frenagem, comparando condições com e sem chuva. Os resultados indicaram que a precipitação influenciou a distribuição do tempo em cada categoria. Sob chuva, os condutores permaneceram mais tempo em faixas de velocidade reduzida, o que corrobora estudos que apontam a adaptação da velocidade como resposta à

menor aderência do pavimento e à visibilidade comprometida. A análise estatística (Dunn e Mann-Whitney) confirmou diferenças significativas em variáveis de velocidade e frenagem, enquanto os boxplots revelaram menor dispersão sob chuva, sugerindo que os motoristas tendem a adotar uma condução mais homogênea em condições adversas. Portanto, a chuva impacta a dinâmica da condução, reduzindo a velocidade média e alterando a permanência em faixas de aceleração e frenagem.

A Hipótese 2 avaliou diferenças no comportamento dos condutores entre os períodos de iluminação diurno e noturno, ambos sob chuva. Os resultados mostraram que a visibilidade reduzida à noite levou parte dos motoristas a reduzir ainda mais a velocidade, enquanto outros mantiveram comportamento semelhante ao observado no período diurno. Para as variáveis de aceleração e frenagem, o teste estatístico Mann-Whitney revelou diferenças estatisticamente significativas entre os dois períodos, indicando que a menor visibilidade noturna induziu a ajustes na condução, com acelerações mais progressivas e freadas mais intensas, em função da percepção reduzida da via. Conclui-se que a combinação entre chuva e baixa luminosidade impacta o comportamento de forma diferenciada entre os condutores, exigindo estratégias adaptativas específicas.

A Hipótese 3 investigou diferenças entre os períodos de pico e entre picos, ambos sob chuva. Os resultados confirmaram que a interação entre precipitação e fluxo de veículos exerce influência sobre o comportamento dos condutores, especialmente no tempo de permanência em diferentes faixas de velocidade, aceleração e frenagem. Os dados indicaram que, independentemente do período analisado, os motoristas tenderam a privilegiar faixas de menor velocidade, refletindo uma postura mais cautelosa em condições adversas. As análises estatísticas, conduzidas tanto na amostra original quanto no bootstrap, evidenciaram diferenças significativas em algumas faixas, sugerindo que a adaptação dinâmica do comportamento é modulada pelo nível de densidade do tráfego. Além disso, padrões de aceleração e frenagem mostraram menor frequência de manobras bruscas nos períodos de maior densidade, indicando uma estratégia de redução de riscos e maior controle sob chuva.

A Hipótese 4 investigou como a chuva afeta velocidade, aceleração e frenagem dos motoristas individualmente, analisando 16 condutores que dirigiram em ambas as condições climáticas. Os resultados indicaram que a velocidade relativa variou conforme o motorista: alguns reduziram a velocidade sob chuva, enquanto outros mantiveram ou aumentaram o ritmo. A aceleração mostrou tendência de redução para a maioria dos condutores, refletindo um comportamento mais cauteloso. A frenagem apresentou variações significativas, com alguns

motoristas adotando desacelerações mais suaves e outros mantendo padrões similares aos de tempo seco. Os testes estatísticos confirmaram diferenças significativas na condução sob chuva para a maioria dos motoristas, reforçando que a adaptação ao clima adverso não é homogênea.

A Hipótese 5 analisou o impacto da luminosidade (dia e noite) sob chuva no desempenho dos condutores em termos de velocidade, aceleração e frenagem. Foram avaliados três motoristas (L, T e X), que realizaram deslocamentos em ambas as condições. Os resultados indicaram diferentes padrões de adaptação entre os motoristas. O condutor L aumentou a velocidade e a intensidade das acelerações e frenagens à noite, sugerindo uma menor percepção do risco. O motorista T reduziu velocidade e aceleração noturnas, adotando um comportamento mais conservador diante da visibilidade reduzida. Já o condutor X apresentou um padrão mais homogêneo e estável, reduzindo ainda mais as variações na velocidade e frenagem no período noturno. Os testes estatísticos confirmaram diferenças significativas na condução entre dia e noite, reforçando que a adaptação às condições de visibilidade varia conforme o perfil de cada motorista.

A Hipótese 6 analisou o impacto da interação entre precipitação e volume de tráfego (pico e entre picos) no desempenho individual dos condutores em termos de velocidade, aceleração e frenagem. Foram avaliados quatro motoristas (H, L, T e X) que percorreram trajetos sob chuva em ambos os períodos. Os resultados indicaram que o fluxo de tráfego afetou o comportamento dos motoristas, mas de forma distinta entre eles. Os condutores H, L e T apresentaram velocidades e acelerações mais elevadas no período de entre picos, sugerindo maior liberdade para ajustar o ritmo da condução quando o tráfego estava mais fluido. O motorista X manteve um padrão mais homogêneo, sem variações expressivas entre os períodos analisados. No que se refere à frenagem, os motoristas H, L e T intensificaram suas frenagens no período de entre picos, o que pode estar relacionado à necessidade de ajustes mais bruscos em vias menos congestionadas. O condutor X, por outro lado, manteve um padrão de frenagem estável, independentemente do fluxo de tráfego. Os testes estatísticos confirmaram que a densidade veicular influencia a condução sob chuva, limitando a velocidade e tornando as acelerações e frenagens mais homogêneas durante os períodos de pico.

Os resultados deste estudo fornecem informações para o desenvolvimento de políticas de segurança viária. A identificação de padrões de condução sob chuva pode auxiliar na definição de estratégias de engenharia de tráfego, incluindo a revisão de limites de velocidade dinâmicos, que podem ser ajustados conforme as condições meteorológicas.

Além disso, os dados obtidos podem ser utilizados para o aprimoramento de programas de fiscalização. A detecção de padrões de condução inadequada sob chuva pode subsidiar ações de monitoramento por radares inteligentes, que adaptem as fiscalizações conforme o clima, garantindo maior segurança nas vias urbanas.

Os resultados também podem ser utilizados na formação e educação de condutores, contribuindo para o desenvolvimento de campanhas educativas sobre os riscos da condução sob chuva. Programas de formação de motoristas podem ser aprimorados com base nos padrões identificados neste estudo, promovendo maior conscientização sobre a necessidade de adaptação do comportamento ao dirigir em condições adversas.

7.1 Limitações da Pesquisa

Esta pesquisa apresentou diversas contribuições para a compreensão do impacto da precipitação e do período da viagem (pico e entre pico - diurno e noturno) sobre a velocidade, aceleração e frenagem dos condutores. Porém, algumas limitações devem ser consideradas na interpretação dos resultados e para o aprimoramento de investigações futuras.

Uma das principais limitações está relacionada às características das vias utilizadas. Diferentes condições de infraestrutura, sinalização e nível de congestionamento podem ter impactado os resultados, tornando necessária uma abordagem que considere a fluidez real do tráfego em cada trajeto percorrido pelo condutor. Nesse estudo considerou-se apenas a diferenciação entre os períodos de pico e entre pico, não sendo observado por exemplo, se a via que o condutor percorreu apresentou aumento no volume de tráfego no período de pico.

Além disso, esta pesquisa não analisou a influência da iluminação artificial. A visibilidade reduzida pode alterar a percepção do risco e a tomada de decisão dos condutores, impactando as estratégias de velocidade, aceleração e frenagem. Neste contexto, investigações futuras podem incorporar variáveis associadas à intensidade da iluminação viária e à presença de áreas com baixa visibilidade, proporcionando uma avaliação mais detalhada dos efeitos da direção noturna sob chuva.

A captação de dados meteorológicos também é uma limitação, uma vez que as informações foram coletadas por estações meteorológicas situadas a determinadas distâncias dos percursos analisados. Dessa forma, a intensidade da precipitação registrada pode não refletir precisamente as condições climáticas enfrentadas pelos motoristas ao longo do trajeto. A

utilização de sensores embarcados nos veículos ou de dados meteorológicos em tempo real poderia minimizar essa incerteza e aprimorar a acurácia dos resultados.

Além disso, não foram considerados fatores individuais dos motoristas, como nível de experiência, percepção de risco e estratégias pessoais de adaptação ao tráfego e às condições meteorológicas. A inclusão dessas variáveis permitiria avaliar como aspectos cognitivos e comportamentais influenciam a resposta dos condutores a diferentes cenários viários e ambientais.

Outra limitação da pesquisa está relacionada ao tamanho da amostra utilizada. O estudo considerou um número restrito de motoristas na análise individualizada, o que pode limitar a generalização dos resultados para a população. Diferenças individuais no estilo de condução, percepção de risco e estratégias de adaptação ao tráfego e às condições meteorológicas podem influenciar os padrões de velocidade, aceleração e frenagem. Uma amostra maior permitiria uma análise mais representativa e robusta, reduzindo a influência de particularidades individuais e possibilitando a identificação de tendências mais amplas no comportamento dos condutores sob diferentes cenários de tráfego e condições climáticas.

7.2 Recomendações para trabalhos futuros

Como recomendações para trabalhos futuros, sugere-se:

- Investigar um número maior de condutores, permitindo análises estatisticamente mais robustas e generalizáveis sobre os padrões de velocidade, aceleração e frenagem.
- Examinar a influência da iluminação pública nas decisões dos motoristas, especialmente em períodos noturnos, para entender como a visibilidade afeta a adaptação da condução sob chuva.
- Utilizar sensores embarcados nos veículos para coletar informações detalhadas sobre a precipitação e visibilidade ao longo do percurso, minimizando a dependência de dados fornecidos por estações meteorológicas fixas.
- Ampliar a análise para outros eventos meteorológicos, como neblina, vento forte e diferentes intensidades de precipitação, a fim de compreender como cada fator impacta a segurança e a dinâmica da condução.

- Considerar o tipo de via na avaliação do comportamento do condutor, uma vez que o condutor pode utilizar vias em seu trajeto que não sofrem aumento do volume de tráfego no período de pico.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGARWAL, M.; MAZE, T. H.; SOULEYRETTE, R. Impact of Weather on Urban Freeway Traffic Flow Characteristics and Facility Capacity. In **Proceedings of the 2005 mid-continent transportation research symposium** (Vol. 9).
- AGARWAL, M.; MAZE, T. H.; SOULEYRETTE, R. The Weather and Its Impacts on Urban Freeway Traffic Operations. **Transportation Research Board (TRB) 85th Annual Meeting Compendium of Papers**. Washington, D.C., United States of America, 2006.
- AGÊNCIA NACIONAL DE TRANSPORTES TERRESTRES (ANTT). Número de acidentes em rodovias privadas aumentou 146% em 2023. Disponível em: <https://www.poder360.com.br/infraestrutura/numero-de-acidentes-em-rodovias-privadas-aumentou-146-em-2023/>. Acesso em: 14 set. 2024.
- AGRAMUNT, S. Naturalistic driving behaviour and self-regulation practices among older drivers with bilateral cataract: a prospective cohort study. Tese de Doutorado. Curtin University, 2018.
- ALVES, E. J. Métodos de *bootstrap* e aplicações em problemas biológicos. 2013.
- ALI, S.; AHMED, A.; YANG, K. Risk perception and driving behavior under adverse weather conditions: a case study on urban highways. **Transportation Research Part F: Traffic Psychology and Behaviour**, v. 78, p. 127–145, 2021.
- AMANCIO, E. C. Influência de dispositivos de fiscalização eletrônica de velocidade no comportamento do condutor em cenário urbano. Dissertação (Mestrado em Engenharia Civil) – Universidade Tecnológica Federal do Paraná, Curitiba, 2021.
- ASAMER, J.; REINTHALER, M. Estimation of Road Capacity and Free Flow Speed for Urban Roads Under Adverse Weather Conditions. In: **Annual Conference on Intelligent Transportation Systems**, Madeira Island, Portugal, 2010.
- BAKHSHI, V.; AGHABAYK, K.; PARISHAD, N.; SHIWAKOTI, N. Evaluating rainy weather effects on driving behaviour dimensions of driving behaviour questionnaire. **Journal of advanced transportation**, 2022(1), 6000715, 2022.
- BAZÍLIO, G. S., GUIMARÃES, R. A., NAZIF-MUNOZ, J. I., OUIOMET, M. C., MAMRI, A.; MORAIS NETO, O. L. Estimate of the magnitude of risky and protective behaviors associated with road traffic injuries in capitals participating in the Life in Traffic Project of Brazil. **PLoS one**, 17(10), e0275537, 2022.

- BEAN, J. D., KAHANE, C. J., MYNATT, M., RUDD, R. W., RUSH, C. J., & WIACEK, C. Fatalities in frontal crashes despite seat belts and air bags—review of all CDS cases—Model and Calendar years 2000-2007—122 fatalities. **National Highway Traffic Safety Administration** 1200 New Jersey Avenue SE. Washington, DC 20590 2009.
- BENÍTEZ, F. G.; ROMERO, L. M.; CÁCERES, N.; DEL CASTILLO, J. M. Estimating of *bootstrap* confidence intervals for freight transport matrices. **Procedia - Social and Behavioral Sciences**, v. 111, p. 1155–1164, 2014. DOI: [10.1016/j.sbspro.2014.01.150] (<https://doi.org/10.1016/j.sbspro.2014.01.150>).
- BERTINI, R. L. Congestion and its extent. In: **Access To Destinations**. Emerald Group Publishing Limited, 2005. 11-38.
- BERTINI, R. L.; MONSERE, C. M. Effects of weather on traffic speed, volume, and accidents: a review of empirical findings. In: **Transportation Research Board Annual Meeting**, 2007, Washington, D.C. Proceedings...**Transportation Research Board**, 2007.
- BILLOT, R.; FAOUZI, N.-E.E.; VUYST, F.D. Multilevel Assessment of the Impact of Rain on Drivers' Behavior: Standardized Methodology and Empirical Analysis. **Transportation research record**, v. 2107, n. 1, p. 134-142, 2009.
- BLANCHARD, R. A.; MYERS, A. M.; PORTER, M. M. Correspondence between self-reported and objective measures of driving exposure and patterns in older drivers. **Accident Analysis & Prevention**, v. 42, n. 2, p. 523-529, 2010.
- BORGUEZANI, J. R. DOS SANTOS, P. A. B., OSÓRIO, F. D. S., & BASTOS, J. T. Plataforma de coleta de dados naturalísticos de segurança viária. In *34º Congresso da Associação Nacional de Pesquisa e Ensino em Transportes (ANPET)*.BRASIL, 2020.
- BRASIL. **Estatísticas do sistema de informações de mortalidade**. 2021a.
- BRASIL. **População brasileira**. 2021b.
- BUCSUHÁZY, K.; MATUCHOVÁ, E.; ZŮVALA, R.; MORAVCOVÁ, P.; KOSTÍKOVÁ, M., MIKULEC, R. Human factors contributing to the road traffic accident occurrence. **Transportation Research Procedia**, 45, 555–561, 2020. <https://doi.org/10.1016/j.trpro.2020.03.057>.
- CAI, X.; LU, J. J.; XING, Y.; JIANG, C.; LU, W. Analyzing driving risks of roadway traffic under adverse weather conditions: In case of rain day. **Procedia - Social and**

- Behavioral Sciences**, 96, 2563–2571. <https://doi.org/10.1016/j.sbspro.2013.08.287>, 2013.
- CALEFFI, F.; S. LUCCHESI; M. J. ANZANELLO E H. CYBIS. Influência das condições climáticas e de acidentes na caracterização do comportamento do tráfego em rodovias. **Transportes**, v. 24, n. 4, p. 57–63, 2016.
- CAMACHO, F. J.; GARCÍA, A.; BELDA, E. Analysis of impact of adverse weather on freeway free-flow speed in Spain. **Transportation Research Record**, v. 2169, n. 1, p. 150-159, 2010.
- CAMPBELL, K. L. The SHRP 2 Naturalistic Driving Study: Addressing Driver Performance and Behavior in Traffic Safety. **TR News**, n. 282, 2012.
- CARMO, C. R. S.; DE LIMA, A. D. Métodos quantitativos e pesquisa contábil: um estudo de caso relacionado a pequenas amostras de dados. **Contabilometria**, v. 5, n. 1, 2018.
- CARSTEN, O., HIBBERD, D., BÄRGMAN, J., KOVACEVA, J., PEREIRA COCRON, M., DOTZAUER, M., ... & FORCOLIN, F. Driver distraction and inattention, UDRIVE Consortium. 2017.
- CHEN, C.; ZHAO, X.; LIU, H.; REN, G.; LIU, X. Influence of adverse weather on drivers' perceived risk during car following based on driving simulations. **Journal of Modern Transportation**, v. 27, p. 282–292, 2019. Disponível em: <https://doi.org/10.1007/s40534-019-00197-4>. Acesso em: 6 jul. 2025.
- CHOUDHARY, P.; VELAGA, N. R. Modelling driver distraction effects due to mobile phone use on reaction time. **Transportation Research Part C: Emerging Technologies**, v. 77, p. 351-365, 2017.
- CLARK, Stephen D.; MCKIMM, John. Estimating confidence intervals for transport Mode share. **Journal of Transportation and Statistics**, v. 8, n. 2, p. 894-911, 2005.
- Código de Trânsito Brasileiro. Lei n.º 9.503, de 23 de setembro de 1997. Institui o Código de Trânsito Brasileiro. *Diário Oficial da União*, Brasília, DF, 24 set. 1997. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/19503.htm. Acesso em: 14 set. 2024.
- CONNOR. Driver sleepiness and risk of serious injury to car occupants: population based case control study. **BMJ**, v. 324, n. 7346, p. 1125, 2002.

- DA SILVA FILHO, A. S. Inferência em amostras pequenas: método *bootstrap*. **Revista de Ciências exatas e tecnologia**, v. 5, n. 5, p. 115-126, 2010.
- DAS, A. KHAN, M. N., AHMED, M. M., & WULFF, S. S. Cluster analysis and multi-level modeling for evaluating the impact of rain on aggressive lane-changing characteristics utilizing naturalistic driving data. **Journal of Transportation Safety & Security**, 14(12), 2137-2165, 2022.
- D'APICE. Optimization of Traffic Behavior via Fluid Dynamic Approach. **Urban Transport and Hybrid Vehicles**, p. 103, 2010.
- DENATRAN, **Departamento Nacional de Trânsito. Estatística: Frota**. Disponível em: <<http://www.denatran.gov.br/index.htm>>. Acesso em: 15 de setembro de 2024.
- DEWAR, Robert; OLSON, Paul. **Human factors in traffic safety**. 2. ed. Tucson: Lawyers & Judges Publishing Company, 2007.
- DINGUS, T. A.; GUO, F.; LEE, S.; ANTIN, J. F.; PEREZ, M.; BUCHANAN-KING, M.; HANKEY, J. Driver crash risk factors and prevalence evaluation using naturalistic driving data. **Proceedings of the National Academy of Sciences**, 113(10), 2636-2641, 2016
- DOWNS, Anthony. Why traffic congestion is here to stay... and will get worse. **Access Magazine**, v. 1, n. 25, p. 19-25, 2004.
- DOTZAUER, M., STEMMLER, E., UTESCH, F., BÄRGMAN, J., GUYONVARCH, L., KOVACEVA, J., CARSTEN, O. Risk factors, crash causation and everyday driving. UDRIVE Deliverable 42.1. EU FP7 Project UDRIVE **Consortium.**, 2017 https://doi.org/10.26323/UDRIVE_D42.1.
- DOZZA, M.; FLANNAGAN, C. A. C.; SAYER, R. Real-world effects of using a phone while driving on lateral and longitudinal control of vehicles. **Journal of Safety Research**, v. 55, p. 81-87, 2015.
- EDWARDS, J. B. Speed adjustment of motorway commuter traffic to inclement weather. **Transportation research part F: traffic psychology and behaviour**, v. 2, n. 1, p. 1-14, 1999.
- EBRAHIMI DARKHANEH, Mehdi; EFFATI, Meysam; ARABANI, Mahyar. **Factors affecting the injury severity of head-on crashes on undivided rural roads under**

- different weather conditions.** *International Journal of Transportation Science and Technology*, 2025. DOI: <https://doi.org/10.1016/j.ijtst.2025.02.007>.
- EENINK, R.; BARNARD, Y.; BAUMANN, M.; AUGROS, X.; UTESCH, F. **UDRIVE: The European Naturalistic Driving Study**, 2014.
- EFRON, B.; TIBSHIRANI, R. J. **An Introduction to the *bootstrap***. Nova Iorque: Chapman Hall, Inc, 1993.
- EL FEROUALI, Soukaina; ELAMRANI ABOU ELASSAD, Zouhair; ABDALI, Abdelmounaïm. Understanding the Factors Contributing to Traffic Accidents: Survey and Taxonomy. In: **The International Conference on Artificial Intelligence and Smart Environment**. Cham: Springer Nature Switzerland, 2023. p. 214-221.
- ELVIK, RUNE; HØYE, ALENA; VAA, TRULS; SØRENSEN, MICHAEL. The Power Model of the relationship between speed and road safety: Update and new analyses. Oslo: **Institute of Transport Economics**, 2009. Disponível em: <https://www.toi.no/getfile.php?mmfileid=13206>. Acesso em: 14 set. 2024.
- ELYOUSOUFI, A.; WALKER, C. L.; BLACK, A. W.; DEGIROLAMO, G. J. The Relationships between Adverse Weather, Traffic Mobility, and Driver Behavior. **Meteorology**, 2(4), p. 489-508, 2023.
- ERSAN, Ö., ÜZÜMCÜOĞLU, Y., AZIK, D., FINDIK, G., KAÇAN, B., SOLMAZER, G., ... & XHELADINI, G. The relationship between self and other in aggressive driving and driver behaviors across countries. *Transportation research part F: traffic psychology and behaviour*, 66, 122-138, 2019.
- ESSIEN, A., PETROUNIAS, I., SAMPAIO, P., & SAMPAIO, S. The impact of rainfall and temperature on peak and off-peak urban traffic. In: **International Conference on Database and Expert Systems Applications**. Cham: Springer International Publishing, 2018. p. 399-407.
- ETIKA, A. A.; ADEKE, P. T.; UBANA, G. O. An Assessment of the Relationship Between Speed and Road Safety. **Transactions on Machine Learning and Artificial Intelligence** 11(3), 2023.
- FARIA, M. V.; BAPTISTA, P. C.; FARIAS, T. L.; PEREIRA, J. M. S. Assessing the impacts of driving environment on driving behavior patterns. **Transportation, Springer**, v. 47, n. 3, p. 1311-1337, 2020.

- FERRAZ, C. A. C. **Segurança no trânsito: fundamentos e aplicações**. 2. ed. São Carlos: Editora Claridade, 2023.
- GADDA, T. M. C.; AMANCIO, E. C.; SANTOS, P. A. B. d. Estudo Naturalístico de Direção no Brasil: metodologia e resultados preliminares. **Congresso Brasileiro de Trânsito e Mobilidade Urbana**, 2021. Anais eletrônicos. Disponível em: <https://www.revistatransportes.org.br>. Acesso em: 19 set. 2024.
- GHASEMZADEH, A.; AHMED, M. M. Drivers' lane-keeping ability in heavy rain: Preliminary investigation using SHRP 2 naturalistic driving study data. **Transportation Research Record**, v. 2663, n. 1, p. 99-108, 2017.
- GONZALEZ, F. M. *et al.* Naturalistic Driving Studies: expanding the methodology for Brazilian urban contexts. **Journal of Transport Safety**, v. 18, n. 4, p. 235-246, 2022.
- GUO, F.; FANG, Y. Individual driver risk assessment using naturalistic driving data. **Accident Analysis & Prevention**, v. 61, p. 3-9, 2013.
- HABERMEHL, C.; BENNER, A.; KOPP-SCHNEIDER, A. Addressing small sample size bias in multiple-biomarker trials: Inclusion of biomarker-negative patients and Firth correction. **Biometrical Journal**, v. 60, n. 2, p. 275-287, 2018.
- HARRÉ, N. Risk evaluation, driving, and adolescents: A typology. **Developmental Review**, v. 20, n. 2, p. 206-226, 2000.
- HASSAN, S. A.; WONG, L.; MASHROS, N.; ALHASSAN, H. M.; SUKOR, N. S. A.; ROHANI, M.; MINHANS, A. Operating speed of vehicles during rainfall at night: case study in Pontian, Johor. **Jurnal Teknologi**, v. 78, n. 7-2, p. 9-18, 2016.
- HOFFMANN, J. **Avaliação: mito e desafio: uma perspectiva construtivista**. São Paulo: EPU, 2003.
- HOGEMA, J. H. Effects of rain on daily traffic volume and speed. **Transportation Research Record: Journal of the Transportation Research Board**, n. 1550, p. 64-70, 1996.
- HOSSAIN, M.; *et al.* Performance analysis of Adaptive Cruise Control in wet and dry weather conditions using CARLA Simulator. **arXiv.org**, 2024. Disponível em: <https://arxiv.org/abs/2405.01504>. Acesso em: 07 mar. 2025.

- HOU, T.; MAHMASSANI, H.S.; ALFELOR, R.M.; KIM, J.; SABERI, M. Calibration of Traffic Flow Models Under Adverse Weather and Application in Mesoscopic Network Simulation. **Transp. Res. Rec. J. Transp. Res. Board** 2013, 2391, 92–104.
- HRANAC, R., STERZIN, E., KRECHMER, D., RAKHA, H. A., FARZANEH, M., & ARAFEH, M. (2006). Empirical studies on traffic flow in inclement weather. (VT-2008-06). Washington, DC: United States. **Federal Highway Administration**. Retrieved from <http://ops.fhwa.dot.gov/publications/weatherempirical/weatherempirical.pdf>
- HODGES, J. L.; LEHMANN, E. L. Estimates of location based on rank tests. *Annals of Mathematical Statistics*, v. 34, n. 2, p. 598–611, 1963.
- IBRAHIM, A. T.; HALL, F. L. Effect of adverse weather conditions on speed-flow-occupancy relationships. In: **Transportation Research Record**, n. 1457, 1994.
- ILIAS, D.; CARAVATTO BARAS, F.; CRESPO, M.; PARDO DE ALEXANDRE, G.; MARTINEZ, J. E. CRISTINA, V., ... & NASCIMENTO, D. Mobile phone using while driving among young university students. **Revista da Faculdade de Ciências Médicas de Sorocaba**, v. 14, p. 123-125, 2012.
- IVERS, R.; SENSERRICK, T.; BOUFIOUS, S.; STEVENSON, M.; CHEN, H. Y.; WOODWARD, M.; NORTON, R. Novice drivers' risky driving behavior, risk perception, and crash risk: findings from the DRIVE study. **American journal of public health**, v. 99, n. 9, p. 1638-1644, 2009.
- JÄGERBRAND AK, SJÖBERGH J. Effects of weather conditions, light conditions, and road lighting on vehicle speed. **Springer Plus**. 2016.
- JUNG, K.; LEE, J.; GUPTA, V.; CHO, G. Comparison of *bootstrap* confidence interval methods for GSCA using a Monte Carlo simulation. **Frontiers in psychology**, v. 10, p. 2215, 2019.
- KVAM, P.; VIDA KOVIC, B.; KIM, S. Nonparametric statistics with applications to science and engineering with R. **John Wiley & Sons**, 2022.
- KILPELÄINEN, M.; SUMMALA, H. Effects of weather and weather forecasts on driver behaviour. **Transportation Research Part F: Traffic Psychology and Behaviour**, 10 (2007).

- KITA, E., LURIA, G., PINDEK, S., ALBERT, G., & LOTAN, T. The use of risk homeostasis theory to reduce smartphone use during low-speed driving. **Accident Analysis & Prevention**, 168, 106596, 2022.
- KONSTANTOPOULOS, P.; CHAPMAN, P.; CRUNDALL, D. Driver's visual attention as a function of driving experience and visibility. Using a driving simulator to explore drivers' eye movements in day, night and rain driving. **Accident analysis & prevention**, v. 42, n. 3, p. 827-834, 2010.
- KORDANI, A. Abdi *et al.* Effect of adverse weather conditions on vehicle braking distance of highways. **Civil Engineering Journal**, v. 4, n. 1, p. 46-57, 2018.
- KYTE, M. *et al.* Effect of weather on free-flow speed. **Transportation Research Record**, v. 1776, n. 1, p. 60-68, 2001.
- LAROCCA, A. P. C. *et al.* Analysis of perception of vertical signaling of highways by drivers in a simulated driving environment. **Transportation Research Part F: Traffic Psychology and Behaviour**, p. 401-417, 2018.
- LEÃO, J. C., LEÃO, J. J. C. C., DOS SANTOS, A. B., MARQUES, T. M., & SANTOS, E. M. S. (2021). Inteligência artificial na educação: aplicações do aprendizado de máquina para apoiar a aprendizagem adaptativa. **Revista Multidisciplinar do Vale do Jequitinhonha. ReviVale**, v. 1, n. 1, 2021.
- LIU, X.; WU, B.; ZHAO, Y.; ZHENG, L. Analysis of speed characteristics of urban expressways under rainy conditions. In: **2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)**, pp. 1-6, 2017. IEEE.
- LIU, X.; WANG, Y.; ZHANG, H. Adaptation strategies of drivers to wet road conditions: a study based on naturalistic driving data. **Journal of Safety Research**, v. 82, p. 93-104, 2022.
- MADDALA, G. S. **Introdução à Econometria**. 3ª ed., Editora LTC: Rio de Janeiro, p. 318, 2003.
- MALHOTRA, N., CHARLTON, S., STARKEY, N., & MASTERS, R. (2018). Driving speed choice: The role of conscious monitoring and control (reinvestment) when driving. **Transportation research part F: traffic psychology and behaviour**, v. 57, p. 115-128, 2018
- MANUAL, H. C. Highway capacity manual. Washington, DC, 2000.

- MAYHEW, D. R.; SIMPSON, H. M.; PAK, A. Changes in collision rates among novice drivers during the first months of driving. **Accident analysis & prevention**, v. 35, n. 5, p. 683-691, 2003.
- MONTGOMERY, D. C.; RUNGER, G. C. **Estatística aplicada e probabilidade para engenheiros**. 2.ed. Rio de Janeiro: LTC, 2003.
- MOORE, D. S.; McCABE, G. P.; DUCKWORTH, W. M.; SCLOVE, S. L. **The Practice of Business Statistics: Using data for decisions**. 1ª ed. LTC: Rio de Janeiro, p. 785, 1996
- MORAIS, M. F. **Pesquisa Operacional Aplicada** -Apostila. Curso de Engenharia de Produção Agroindustrial. Fecilcam: Campo Mourão, 2010.
- MOREIRA, R.M. Avaliação do Impacto de Condições Ambientais Adversas no Processo de Condução Veicular em Corredores Arteriais de Fortaleza, Monografia apresentada ao Curso de Engenharia Civil da Universidade Federal do Ceará, 2018.
- MUDELSEE, M.; ALKIO, M. Quantifying effects in two-sample environmental experiments using *bootstrap* confidence intervals. **Environmental Modelling & Software**, v. 22, n. 1, p. 84-96, 2007.
- NATIONAL CENTER FOR STATISTICS AND ANALYSIS. 2016 fatal motor vehicle crashes: Overview (Traffic Safety Facts Research Note. Report No. DOT HS 812 456). Washington, DC: **National Highway Traffic Safety Administration**, 2017. Disponível em: <https://crashstats.nhtsa.dot.gov/Api/Public/ViewPublication/812456>. Acessado em: 10/10/2024.
- NATIONAL HIGHWAY TRAFFIC SAFETY ADMINISTRATION (NHTSA). Asleep at the Wheel: A National Compendium of Efforts to Eliminate Drowsy Driving. Washington, DC: **U.S. Department of Transportation**, 2017. (DOT HS 812 352).
- NEALE, V. L., DINGUS, T. A., KLAUER, S. G., SUDWEEKS, J. D., & GOODMAN, M. J. An overview of the 100-car naturalistic driving study and findings. Paper presented at the 19th **International Technical Conference on the Enhanced Safety of Vehicles**, Washington, D.C, 2005.
- NI, X., HUANG, H., LI, R., CHEN, A., LIU, Y., XING, H., ...; WANG, M. Synergistic Influence of Rainstorm and Waterlogging on Drivers' Driving Behavior—An Experimental Study Based on High-Fidelity Driving Simulator. **Sustainability**, v. 14, n. 14, p. 8517, 2022.

- NITSCHKE, P.; VAN NES, N.; HOUTENBOS, M.; HOEDEMAEKER, M. Using Naturalistic Driving Data for Behavioural Research in Europe: The UDRIVE Project. In: *Proceedings of the 5th International Conference on Driver Distraction and Inattention (DDI2017)*, Paris, 2017.
- OBSERVATÓRIO NACIONAL DE SEGURANÇA VIÁRIA (ONSV). **O Brasil tem aumento de mortes no trânsito em 2021**. São Paulo, maio de 2023. Disponível em: <https://www.onsv.org.br/comunicacao/brasil-tem-aumento-de-mortes-no-transito-em-2021#:~:text=Em%202021%2C%20o%20Brasil%20apresentou,com%20os%20dados%20de%202020>. Acesso em: 13 jun. 2023.
- ONYENEKE, C.; EGUZOUWA, C.; MUTABAZI, C. Modeling the effects of traffic congestion on economic activities-accidents, fatalities and casualties. **Biomedical Statistics and Informatics**, v. 3, n. 2, p. 7-14, 2018.
- OSORIO, Carolina; NANDURI, Karthik. Urban transportation emissions mitigation: coupling high-resolution vehicular emissions and traffic models for traffic signal optimization. *Transportation Research Part B: Methodological*, v. 81, p. 520-538, 2015.
- ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS). *Global status report on road safety 2018*. Disponível em: <https://www.who.int/publications-detail/global-status-report-on-road-safety-2018>. Acesso em: 13 jun. 2023.
- PANTANGI, S.S.; FOUNTAS, G.; ANASTASOPOULOS, P.C.; PIEROWICZ, J.; MAJKA, K.; BLATT, A. Do High Visibility Enforcement programs affect aggressive driving behavior? An empirical analysis using Naturalistic Driving Study data. **Accident Analysis & Prevention**, v. 138, p. 105361, 2020.
- PAWAR, N. M. Modelling braking behaviour and accident probability of drivers under increasing time pressure conditions. **Accident Analysis & Prevention**, v. 136, p. 105401, 2020.
- PI, M.; YEON, H.; SON, H.; JANG, Y. Visual cause analytics for traffic congestion. **IEEE Transactions on Visualization and Computer Graphics**, v. 27, n. 3, p. 2186-2201, 2019.
- PISANO, P. A.; GOODWIN, L. C.; ROSSETTI, M. A. U.S. highway crashes in adverse road weather conditions. U.S. **DOT Federal Highway Administration**, Washington, D.C., 2005.

- QIU, L.; NIXON, W. A. Effects of adverse weather on traffic crashes: systematic review and meta-analysis. **Transportation Research Record**, v. 2055, n. 1, p. 139-146, 2008.
- RAHMAN, A.; LOWNES, N. E. Analysis of rainfall impacts on platooned vehicle spacing and speed. **Transportation research part F: traffic psychology and behaviour**, v. 15, n. 4, p. 395-403, 2012.
- RAHMAN, M. M.; LOWNES, N. E. Driver performance and behavior in adverse weather conditions: an investigation using the SHRP2 naturalistic driving study data – Phase 2. Relatório Final WY-18/05F. **Wyoming Department of Transportation Research Center**, 2018. Disponível em: <https://www.dot.state.wy.us>. Acesso em: 6 jul. 2025.
- RAJALIN, S. The connection between risky driving and involvement in fatal accidents. **Accident Analysis & Prevention**, v. 26, n. 5, p. 555-562, 1994.
- RAKHA, H.; FARZANAHEH, M.; ARAFEH, M.; STERZIN, E. Inclement Weather Impacts on Freeway Traffic Stream Behavior. **Transportation Research Record Journal of the Transportation Research Board**, v. 2071-02, p. 8-18, 2008.
- RAKHA, H. (2009). Validation of Van Aerde's simplified steady-state car-following and traffic stream model. **Transportation Letters** 1(3), 227–244, 2009.
- RHINO CAR HIRE. Mortes no Trânsito por País. **Rhino Car Hire**, 2016. Disponível em: <https://www.rhinocarhire.com/Mortes-no-Trânsito-por-País>. Acesso em: 14 set. 2024.
- RICHARD, C. M., LEE, J., ATKINS, R.; BROWN, J. L. Using SHRP2 naturalistic driving data to examine driver speeding behavior. **Journal of safety research**, 73, 271-281, 2020.
- RIOS, P. A. A.; MOTA E. L. A.; FERREIRA, L. N.; CARDOSO, J. P.; RIBEIRO, V. M.; SOUZA, B. S. Fatores associados a acidentes de trânsito entre condutores de veículos: achados de um estudo de base populacional. **Ciência & Saúde Coletiva**. 2020. <https://doi.org/10.1590/1413-81232020253.1192201>.
- ROZESTRATEN, R. J. A. **Psicologia do trânsito: conceitos e processos básicos**. São Paulo: EPU-EDUSP, 1988.
- ROZESTRATEN, R. J. A.; DOTTA, Á. J. **Os sinais de trânsito e o comportamento seguro**. Porto Alegre: Sagra Luzzatto, 1996.

- RUMAR, K. The role of perceptual and cognitive filters in observed behavior. In: **Human Behavior And Traffic Safety**, p. 151-170, 1985.
- SABIR, M. Weather and travel behaviour. Amsterdam: **Vrije Universiteit**, 2011. (PhD Dissertation).
- SAKHARE, R. S.; ZHANG, Y.; Li, H.; BULLOCK, D. M. Impact of rain intensity on interstate traffic speeds using connected vehicle data. **Vehicles**, 5(1), p. 133-155, 2023.
- SANTOS, M. I. dos *et al.* Conceito, configuração e aplicação de um simulador de direção no Brasil – Estudo de caso. **Transportes**, v. 25, n. 2, p. 1-14, 2017.
- SANTOS, P. A. B. dos; BORGUEZANI, M. R.; GADDA, T. M. C. Análise do Comportamento de Motoristas em Vias Urbanas: uma abordagem naturalística. *Revista de Transportes*, v. 11, n. 2, p. 45-59, 2021.
- SEACRIST, T.; MAHESHWARI, J.; SARFARE, S.; CHINGAS, G.; THIRKILL, M.; LOEB, H. S. In-depth analysis of crash contributing factors and potential ADAS interventions among at-risk drivers using the SHRP 2 naturalistic driving study. **Traffic Injury Prevention**, 22(sup1), p. S68-S73, 2021. Disponível em: <https://doi.org/10.1080/15389588.2021.1979529>.
- STERN, A. D., V. SHAH, L. GOODWIN, AND P. PISANO. Analysis of weather impacts on traffic flow in metropolitan Washington DC. 2003.
- SHARAFELDIN, M.; ALBATAYNEH, O.; FARID, A.; KSAIBATI, K. A Bayesian Approach to Examine the Impact of Pavement Friction on Intersection Safety. **Sustainability**, v. 14, n. 19, p. 12495, 2022.
- SILVA, A. L. *et al.* **O Papel dos Estudos Naturalísticos na Segurança Viária no Brasil.** Revista de Engenharia de Transportes, v. 9, n. 1, p. 55-66, 2020.
- SINGH, H.; KATHURIA, A. Analyzing driver behavior under naturalistic driving conditions: A review. **Accident Analysis & Prevention**, v. 150, p. 105908, 2021.
- SMITH, B. L. *et al.* An investigation into the impact of rainfall on freeway traffic flow. In: **83rd Annual Meeting of the Transportation Research Board**, Washington DC, Citeseer, 2004.

- SONG, J.; TIAN, H.; YUAN, X.; GAO, J.; YIN, X.; WANG, Z.; ... ZHANG, H. Study on Risk Prediction Model of Expressway Agglomerate Fog-Related Accidents. **Atmosphere**, v. 14, n. 6, p. 960, 2023.
- STAMOS I., GRAU J.M.S., MITSAKIS E., AIFADOPOULOU G. Modeling Effects of Precipitation on Vehicle Speed. **Transp. Res. Rec. J. Transp. Res. Board.** 2016; 2551:100–110, 2016.
- SUN, W., ABDULLAH, L. N., BINTI KHALID, F., & BINTI SULAIMAN, P. S. Classification of traffic accidents' factors using TrafficRiskClassifier. **International Journal of Transportation Science and Technology**, 17, 328-344, 2025.
- SUNDSTRÖM, Anna. The validity of self-reported driver competence: Relations between measures of perceived driver competence and actual driving skill. **Transportation research part F: traffic psychology and behaviour**, v. 14, n. 2, p. 155-163, 2011.
- SUTO, K.; FUJIWARA, A.; ZHANG, J. Characteristics of Driving Behavior on Dangerous Road, and Influences of Warning Information at Intersections. **Infrastructure Planning Review**, v. 24, p. 887-894, 2007.
- SCHEPERS, P.; VAN LOO, W.; MIERAS, W.; DROLENGA, H.; DE WAARD, D.; HELBICH, M. Built Environment Characteristics and Driving Speed in 30 km/h Zones: A Dutch National Analysis. *Traffic Safety Research*, v. 9, e000091, 2025. DOI:10.55329/dlam1892.
- TANG, J.; WANG, Y.; ZHAO, X. Forecasting Travel Speed in the Rainfall Days to Develop Suitable Strategies for Urban Road Traffic Management. *Journal of Advanced Transportation*, v. 2021, p. 1-13, 2021. DOI:10.1155/2021/6651058.
- TANG, Lanyue; ZHANG, Duo; HAN, Yu; FU, Aohui; ZHANG, He; TIAN, Ye; YUE, Lishengsa; WANG, Di; SUN, Jian. Parallel-computing-based calibration for microscopic traffic simulation model. *Transportation Research Record*, v. 2678, n. 4, p. 279–294, 2023.
- TAKANO, M. S. M. Análise da influência da forma urbana no comportamento de viagens encadeadas com base em padrões de atividades. Dissertação de Mestrado em Transportes – UnB, 2011.
- THIELEN, I. P.; HARTMANN, R. C.; SOARES, D. P. Percepção de risco e excesso de velocidade. **Cadernos de Saúde Pública**, v. 24, p. 131-139, 2008

- THOMAZI, K. R. Elaboração de modelos de previsão de acidentes de trânsito em rodovias rurais de pista simples do estado de Santa Catarina com base no Highway Safety Manual (HSM). 2018. Disponível em: <https://repositorio.ufsc.br/handle/123456789/191122>. Acesso em: 15 set. 2024.
- UNIVERSIDADE FEDERAL DO PARANÁ (UFPR). Estudo Naturalístico de Direção Brasileiro (NDS-BR): análise do comportamento dos condutores. Curitiba: CEPPUR, 2021. Disponível em: <https://www.revistatransportes.org.br>. Acesso em: 19 set. 2024.
- VAN DER HULST, M.; ROTHENGATTER, J. A. T.; MEIJMAN, T. The effects of reduced visibility and time pressure on drivers' distance-keeping behaviour. **Vision in vehicles**, v. 7, p. 311-318, 1999.
- VAN NES, N., BÄRGMAN, J., CHRISTOPH, M., & VAN SCHAGEN, I. The potential of naturalistic driving for in-depth understanding of driver behavior: UDRIVE results and beyond. **Safety Science**, 119, 11-20, 2019.
- VAN OMMEREN, J.; DARGAY, J. Risk compensation and the effects of traffic risk on driving behavior. **Journal of Urban Economics**, v. 60, n. 2, p. 279-296, 2006.
- VAN SCHAGEN, I.; 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**, v. 48, p. 692-701, 2012.
- VRABEL, J.; SARKAN, B.; VASHISTH, A. Change of driver's reaction time depending on the amount of alcohol consumed by the driver-the case study. **Archiwum Motoryzacji**, 87(1), 47-56, 2020.
- WHEATON, A. G. *et al.* Drowsy driving and risk behaviors—10 states and Puerto Rico, 2011–2012. **MMWR Morbidity and Mortality Weekly Report**, v. 63, n. 26, p. 557-562, 2014.
- WIERWILLE, W. W. *et al.* Identification and evaluation of driver errors: overview and recommendations. In: **Highways; Safety And Human Factors: Accidents And The Human Factor**, 2022.
- WILSON DJ (2013) The effect of rainfall and contaminants on road pavement skid resistance. **New Zealand Transport Agency research report**, 515, 2013. Disponível em: <https://www.nzta.govt.nz/assets/resources/research/reports/515/docs/515.pdf>. Acessado em: 13/03/2025.

- WORLD HEALTH ORGANIZATION (WHO). Global status report on road safety 2009. Geneva: World Health Organization, 2009. Disponível em: <https://www.who.int/publications/i/item/global-status-report-on-road-safety-2009>. Acesso em: 14 set. 2024.
- WU, F.; LU, J.; JIANG, J. Estimation of car-following model parameters distribution using *bootstrap* method. In: **Proc.**, 3rd Int. Conf. on Road Safety and Simulation. Washington, DC: Transportation Research Board. 2011.
- WARNAKULASURIYA, R.; DISSANAYAKE, M. B.; KUMARASINGHE, V. N.; GUNATHILAKA, M. T. V. Respecting the Lane: A Lane Departure Identification for ADAS in Various Environmental and Lighting Conditions. *Engineering World*, v. 7, p. 51-60, 2025. DOI:10.37394/232025.2025.7.6.
- WANG, Ping; ZHANG, Yajie; WANG, Saisai; LI, Li; LI, Xiaohui. Forecasting travel speed in the rainfall days to develop suitable variable speed limits control strategy for less driving risk. *Journal of Advanced Transportation*, v. 2021, p. 1-13, 2021. DOI: <https://doi.org/10.1155/2021/6639559>.
- YANG, S.; COOKE, P. How Accurate Is Your Travel Time Reliability? Measuring Accuracy Using *bootstrapping* and Lognormal Mixture Models. **Transportmetrica B: Transport Dynamics**. DOI: 10.1080/15472450.2017.1421075, 2018.
- YEO, J.; LEE, J; JANG, K. The effects of rainfall on driving behaviors based on driving volatility. **International journal of sustainable transportation**, v. 15, n. 6, p. 435-443, 2021
- YOH, K.; OKAMOTO, T.; INOI, H.; DOI, K. Comparative Study on Foreign Drivers' Characteristics Using Traffic Violation and Accident Statistics in Japan. **IATSS Research**, v. 41, p. 94-105, 2017. Disponível em: <http://dx.doi.org/10.1016/j.iatssr.2017.06.004>. Acesso em: 16 set. 2024.
- ZHANG, Z., NIU, Z., LI, Y., MA, X., & SUN, S. Research on the influence factors of accident severity of new energy vehicles based on ensemble learning. **Frontiers in Energy Research**, 11, 1329688, 2023.
- ZÖLLER, I.; ABENDROTH, B.; BRUDER, R. Driver behaviour validity in driving simulators – analysis of the moment of initiation of braking at urban intersections. **Transportation Research Part F: Traffic Psychology and Behaviour**, v. 61, p. 120-130, 2019.