

UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

Pedro Reis e Nunes

**DESENVOLVIMENTO DE MODELO DE REDE NEURAL ARTIFICIAL PARA
PREVISÃO DO DESEMPENHO SUBJETIVO DA SENSACÃO DE DIREÇÃO A
PARTIR DE MÉTRICAS OBJETIVAS DE DINÂMICA VEICULAR LATERAL**

Belo Horizonte

2025

Pedro Reis e Nunes

**DESENVOLVIMENTO DE MODELO DE REDE NEURAL ARTIFICIAL PARA
PREVISÃO DO DESEMPENHO SUBJETIVO DA SENSACÃO DE DIREÇÃO A
PARTIR DE MÉTRICAS OBJETIVAS DE DINÂMICA VEICULAR LATERAL**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Mecânica da Universidade Federal de Minas Gerais, como requisito para obtenção do título de Mestre em Engenharia Mecânica

Orientador: Prof. Dr. Juan Carlos Horta Gutiérrez

Belo Horizonte

2025

N972d

Nunes, Pedro Reis e.

Desenvolvimento de modelo de rede neural artificial para previsão do desempenho subjetivo da sensação de direção a partir de métricas objetivas de dinâmica veicular lateral [recurso eletrônico] / Pedro Reis e Nunes. - 2025.

1 recurso online (111 f. : il., color.) : pdf.

Orientador: Juan Carlos Horta Gutiérrez.

Dissertação (mestrado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Inclui bibliografia.

1. Engenharia mecânica - Teses. 2. Simulação (Computadores) - Teses. 3. Redes neurais (Computação) - Teses. I. Gutiérrez, Juan Carlos Horta. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.

CDU: 621 (043)



UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

FOLHA DE APROVAÇÃO

"DESENVOLVIMENTO DE MODELO DE REDE NEURAL ARTIFICIAL PARA PREVISÃO DO DESEMPENHO SUBJETIVO DA SENSAÇÃO DE DIREÇÃO A PARTIR DE MÉTRICAS OBJETIVAS DE DINÂMICA VEICULAR LATERAL"

PEDRO REIS E NUNES

Dissertação submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Minas Gerais, constituída pelos Professores Dr. Juan Carlos Horta Gutierrez (Orientador - Departamento de Engenharia Mecânica-UFMG), Dr. Pedro Bastos Costa (Departamento de Engenharia Mecânica-UFMG) e Dr. Guilherme Costa Carneiro (Stellantis Automóveis Brasil LTDA), como parte dos requisitos necessários à obtenção do título de "**Mestre em Engenharia Mecânica**", na área de concentração de "**Projeto e Sistemas**".

Dissertação aprovada no dia 17 de julho de 2025.

Por:



Documento assinado eletronicamente por **Juan Carlos Horta Gutierrez, Professor do Magistério Superior**, em 28/07/2025, às 12:34, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Guilherme Costa Carneiro, Usuário Externo**, em 28/07/2025, às 16:13, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Pedro Bastos Costa, Professor do Magistério Superior**, em 28/07/2025, às 19:31, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4413112** e o código CRC **162C5BDE**.

AGRADECIMENTOS

Agradeço aos meus pais, avós, tios e tias pelo apoio incondicional e pelo incentivo constante aos meus estudos.

À minha companheira Geovana, pela presença, parceria e suporte em todos os momentos desta jornada.

Aos colegas da Stellantis, pela construção de um ambiente colaborativo que tanto contribuiu para o meu desenvolvimento profissional e acadêmico — em especial à equipe de simuladores, cuja disponibilidade e dedicação foram fundamentais para a realização deste trabalho.

Ao meu orientador, Prof. Dr. Juan Carlos Horta, pelo incentivo em todas as etapas do curso e pela orientação, essenciais para conclusão desta pesquisa.

À Universidade Federal de Minas Gerais e Escola de Engenharia agradeço a oportunidade de realização do curso de mestrado.

RESUMO

Esse estudo apresenta o desenvolvimento de um modelo de rede neural artificial (RNA) para prever o desempenho subjetivo de veículos a partir de métricas objetivas de dinâmica veicular lateral e sensação de direção. Diferentes segmentos de veículos foram caracterizados por simulações e agrupados por similaridade, sendo posteriormente selecionada uma amostra representativa para avaliação subjetiva. Essas avaliações ocorreram em um simulador de direção, no qual foram atribuídas notas a parâmetros relacionados à resposta direcional, à dinâmica de rolagem e à sensação de direção, de acordo com uma escala comparativa pré-definida. O desempenho da RNA foi comparado ao de outros modelos clássicos de aprendizado de máquina, mostrando-se superior. Além disso, realizou-se uma análise de importância das métricas, identificando os fatores de maior influência na capacidade preditiva do modelo. Os resultados confirmam o potencial da abordagem para apoiar o desenvolvimento veicular, ao alinhar métricas objetivas à percepção do condutor, embora ainda haja necessidade de aprimoramento na previsão de parâmetros específicos.

Palavras-Chave: Dinâmica Veicular; Sensação de Direção; Simulador de Direção; Rede Neural Artificial.

ABSTRACT

This study presents the development of an artificial neural network (ANN) model to predict the subjective performance of vehicles based on objective metrics of lateral vehicle dynamics and steering feel. Different vehicle segments were characterized through simulations and clustered by similarity, with a representative sample subsequently selected for subjective evaluation. These evaluations were carried out in a driving simulator, in which ratings were assigned to parameters related to directional response, roll dynamics, and steering feel, according to a predefined comparative scale. The performance of the ANN was compared with that of other classical machine learning models, proving to be superior. In addition, a metric importance analysis was conducted, identifying the factors with the greatest influence on the model's predictive capability. The results confirm the potential of the approach to support vehicle development by aligning objective metrics with driver perception, although improvements are still needed in the prediction of specific parameters.

Keywords: Vehicle Dynamics; Steering Feel; Driving Simulator; Artificial Neural Network.

LISTA DE ILUSTRAÇÕES

Figura 1. Processo de desenvolvimento em V.....	16
Figura 2. Sistema de controle Condutor-Veículo	17
Figura 3. Sistema de coordenadas	24
Figura 4. Vista frontal do montante.....	26
Figura 5. Vista lateral do montante.	27
Figura 6. Geometria de Ackerman.	28
Figura 7. Ângulo de Deriva.	30
Figura 8. Modelo de Bicicleta.	31
Figura 9. Validação Cruzada	43
Figura 10. Entrada De Volante Incremento Lento de Esterçamento.....	44
Figura 11. Entrada De Volante Varredura Sinusoidal.....	45
Figura 12. Entrada De Volante Senoidal.....	46
Figura 13. Métricas De Subesterço.....	49
Figura 14. Torque No Volante Por Aceleração Lateral.....	49
Figura 15. Ganhos e Tempos de Resposta de AY/AVOL, taxa de guinada/AVOL e taxa de guinada/AY.....	50
Figura 16. Ganho e Tempo de Resposta de TVOL/AVOL.....	51
Figura 17. Ganhos e Tempos de Resposta de rolagem/AY e taxa de rolagem/AVOL.	52
Figura 18. Ciclos TVOL/AY, TVOL/AVOL e AVOL/AY.	53
Figura 19. Fluxograma da metodologia.....	58
Figura 20. Histograma das Métricas Normalizadas.....	60
Figura 21. Matriz De Correlação Inicial.....	61
Figura 22. Matriz De Correlação Final.....	62
Figura 23. Distribuição Inicial Das Métricas	63
Figura 24. Distribuição Final Das Métricas.....	63
Figura 25. Variância Explicada Por Número De Componentes.....	64
Figura 26. Projeção PCA1 x PCA2	65
Figura 27. Matriz de Carga dos Componentes Principais	65
Figura 28. SSE Pelo Número De Agrupamentos	66

Figura 29. Visualização 2D dos Agrupamentos.	67
Figura 30. Verificação Das Separações Por Classe E Fabricante.....	67
Figura 31. Matriz de correlação global.....	70
Figura 32. Consistência entre correlações globais e por grupo	72
Figura 33. Comparação do Erro Quadrático Médio de validação de RNA_1 e RNA_2.....	75
Figura 34. Comparação de R ² de validação de RNA_1 e RNA_2.	75
Figura 35. Curva de aprendizado RNA_1.	76
Figura 36. Curva de aprendizado RNA_2.	76
Figura 37. Histograma Macro 1.....	95
Figura 38. Histograma Macro 2.....	96
Figura 39. Histograma Macro 3.....	96
Figura 40. Distribuição de S1 por Cluster.	97
Figura 41. Distribuição de S2 por Cluster.	97
Figura 42. Distribuição de S3 por Cluster.	98
Figura 43. Distribuição de S4 por Cluster.	98
Figura 44. Distribuição de S5 por Cluster.	99
Figura 45. Distribuição de S6 por Cluster.	99
Figura 46. Distribuição de S7 por Cluster.	100
Figura 47. Distribuição de S8 por Cluster.	100
Figura 48. Distribuição de S9 por Cluster.	101
Figura 49. Matriz de correlação Grupo 0a.....	102
Figura 50. Matriz de correlação Grupo 0b.	103
Figura 51. Matriz de correlação Grupo 1.	104
Figura 52. Matriz de correlação Grupo 2.	105
Figura 53. Matriz de correlação Grupo 3.	106
Figura 54. Matriz de correlação Grupo 4.	107

LISTA DE TABELAS

Tabela 1. Estatísticas descritivas dos parâmetros subjetivos.....	69
Tabela 2. Desempenho dos Modelos Clássicos.....	73
Tabela 3. Comparação de Desempenho entre Redes Neurais.	77
Tabela 4. Comparação de Desempenho entre RNA_2 e Modelos Clássicos.	78
Tabela 5. Melhor modelo por parâmetro subjetivo.	79
Tabela 6. Importância média para parâmetro S1.	80
Tabela 7. Importância média para parâmetro S2.	81
Tabela 8. Importância média para parâmetro S3.	82
Tabela 9. Importância média para parâmetro S4.	83
Tabela 10. Importância média para parâmetro S5.	84
Tabela 11. Importância média para parâmetro S6.	85
Tabela 12. Importância média para parâmetro S7.	86
Tabela 13. Importância média para parâmetro S8.	87
Tabela 14. Importância média para parâmetro S9.	88
Tabela 15. Comparativo univariado para target S1.	108
Tabela 16. Comparativo univariado para target S2.	108
Tabela 17. Comparativo univariado para target S3.	109
Tabela 18. Comparativo univariado para target S4.	109
Tabela 19. Comparativo univariado para target S5.	109
Tabela 20. Comparativo univariado para target S6.	110
Tabela 21. Comparativo univariado para target S7.	110
Tabela 22. Comparativo univariado para target S8.	110
Tabela 23. Comparativo univariado para target S9.	111

LISTA DE ABREVIATURAS E SIGLAS

a^L	Vetor de ativações da l-ésima camada após aplicação da função de ativação
AVOL	Ângulo de esterçamento
AY	Aceleração Lateral
α	Ângulo de deriva / parâmetro de regularização
α_d	Ângulo de deriva do eixo dianteiro
α_t	Ângulo de deriva do eixo traseiro
b	Distância do eixo dianteiro ao centro de gravidade do veículo
b^L	Vetor de viés da l-ésima camada
β_n	Coefficientes do modelo
c	Distância do eixo traseiro ao centro de gravidade do veículo
C	Matriz de covariância
C_α	Rigidez de deriva
CC_α	Coefficiente de deriva
d_i	Distância da amostra ao centro do agrupamento
D	Matriz de autovalores
δ	Esterçamento médio das rodas dianteiras
δ_i	Esterçamento da roda interna
δ_o	Esterçamento da roda externa
EQM	Erro Quadrático Médio
EQM_{multi}	Erro Quadrático Médio para análise multivariada

ε	Termo de erro
F_Y	Força lateral gerada pelo pneu
F_Z	Carga vertical aplicada ao pneu
g	Aceleração da gravidade
KNN	<i>K-Nearest Neighbors</i>
KUG	Gradiente de subesterço
L	Distância Entre eixos
M	Número de variáveis observadas
μ	Média
μ_j	Posição central do agrupamento
N	Número total de observações
R	Raio de curvatura
R^2	Coefficiente de Determinação
REQM	Raiz do Erro Quadrático Médio
RNA_1	Rede Neural Artificial 1
RNA_2	Rede Neural Artificial 2
r_{xy}	Coefficiente de correlação de Pearson entre as variáveis x e y
SSE	Soma dos erros quadráticos
σ	Desvio padrão / função de ativação
σ_{output}	Função de ativação da camada de saída
t	Bitola traseira

T	Número total de árvores
TVOL	Torque no volante
V	Matriz de autovetores
W^L	Matriz de pesos da l-ésima camada
x	Vetor de entrada / Direção x do sistema móvel de coordenadas
X	Valor original da variável / Direção x do sistema fixo de coordenadas
Xmax	Valor máximo da variável no conjunto de dados
Xmin	Valor mínimo da variável no conjunto de dados
Xnormalizado	Valor da variável após a normalização
x_i	Valor da variável x para a observação i
x_n	Variáveis independentes
\bar{x}	Média da variável x
Y	Variável dependente / Direção y do sistema móvel de coordenadas
Y	Direção Y do sistema fixo de coordenadas
y_i	Valor da variável y para a observação i
\bar{y}	Média da variável y
\hat{y}	Vetor de saída
z^L	Vetor de ativações lineares da l-ésima camada
z	Direção z do sistema móvel de coordenadas
Z	Direção z do sistema fixo de coordenadas

SUMÁRIO

1. INTRODUÇÃO	16
1.1 Desempenho subjetivo da sensação de direção e resposta do veículo	17
1.2 Simuladores de direção.....	18
1.3 Aprendizado De Máquina.....	20
1.4 Objetivo geral	22
1.5 Objetivos específicos	22
2. REVISÃO BIBLIOGRÁFICA	23
2.1 Definição do sistema de coordenadas.....	23
2.2 Geometria de suspensão	25
2.2.1 Vista frontal do montante	25
2.2.2 Vista lateral do montante.....	26
2.2.3 Geometria de Ackerman.....	27
2.3 Propriedades mecânicas dos pneus.....	29
2.4 Gradiente de subesterço.....	31
2.5 Aprendizado de máquina	34
2.5.1 O processo de aplicação do aprendizado de máquina	34
2.5.2 Coeficiente de correlação de Pearson.....	36
2.5.3 Normalização dos dados.....	36
2.5.4 Redução da dimensionalidade	37
2.5.5 K-Means	38
2.5.5.1 Regressão linear.....	39
2.5.5.2 Regressão ridge	40
2.5.5.3 K-Nearest Neighbors	40
2.5.5.4 Random Forest.....	41
2.5.6 Redes neurais artificiais.....	41
2.5.7 Validação cruzada.....	43

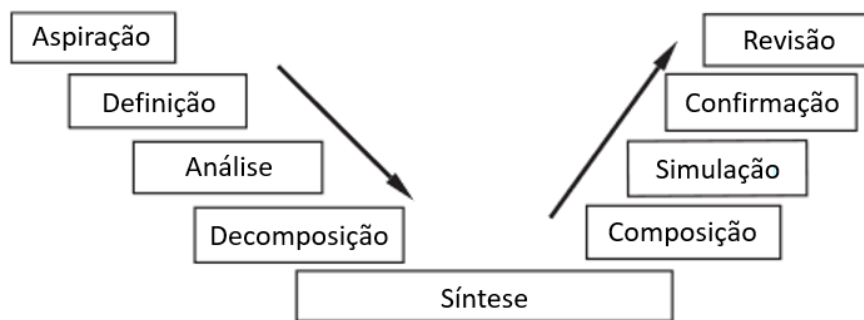
2.6	Testes de malha aberta.....	44
3.	METODOLOGIA	47
3.1	Definição das métricas objetivas	47
3.2	Definição da escala subjetiva	53
3.3	Pré-processamento e tratamento dos dados	55
3.3.1	Remoção de multicolinearidade	55
3.3.2	Normalização dos dados	55
3.4	Agrupamento de veículos similares.....	55
3.5	Previsão do desempenho subjetivo.....	56
3.6	Análise de importância	56
3.7	Implementação computacional	57
4.	RESULTADOS.....	58
4.1	Obtenção dos dados	59
4.2	Tratamento de dados.....	59
4.2.1	Remoção de multicolinearidade	60
4.2.2	Normalização dos dados	63
4.2.3	Análise de componentes principais	64
4.2.4	K-Means	66
4.3	Obtenção das métricas subjetivas.....	68
4.4	Análise de correlações	69
4.5	Aprendizado supervisionado	73
4.5.1	Modelos clássicos de aprendizado de máquina	73
4.5.2	Redes neurais artificiais.....	73
4.5.3	Comparativo dos resultados multivariados	77
4.5.4	Resultados univariados	79
4.5.5	Análise de importância de <i>features</i>	80
4.5.5.1	Prontidão da resposta.....	80
4.5.5.2	Facilidade em manter a trajetória em curva.....	81

4.5.5.3	Atraso da resposta do eixo posterior	82
4.5.5.4	Progressão do ângulo de direção em curvas	83
4.5.5.5	Comportamento de rolagem	84
4.5.5.6	Velocidade de rolagem	85
4.5.5.7	Sensação ao centro.....	86
4.5.5.8	Esforço de direção / progressão.....	87
4.5.5.9	Atraso da resposta direcional.....	88
5.	CONCLUSÕES E CONSIDERAÇÕES FINAIS	89
6.	PROPOSTAS DE TRABALHOS FUTUROS	92
	REFERÊNCIAS	93
	APÊNDICE A - Histogramas gerais dos parâmetros subjetivos obtidos	95
	APÊNDICE B - Distribuição dos parâmetros subjetivos por agrupamento.....	97
	APÊNDICE C - Matrizes de correlação de Pearson para cada agrupamento	102
	APÊNDICE D - Resultados univariados	108

1. INTRODUÇÃO

O desenvolvimento de novos veículos de passeio é um processo complexo que requer a integração multidisciplinar de diversas tecnologias e áreas do conhecimento. Durante a concepção estabelecem-se objetivos específicos, definidos tanto por requisitos legais quanto por exigências mercadológicas associadas ao segmento pretendido. Entre diferentes metodologias para atender a esses requisitos e exigências para o desenvolvimento de um veículo, o "Processo em V", apresentado na figura 1, é uma metodologia aplicada para assegurar o atingimento de objetivos, o processo caracteriza-se por uma abordagem sistemática dividida em duas etapas principais.

Figura 1. Processo de desenvolvimento em V



Fonte: Adaptado de (BLUNDELL; HARTY, 2004)

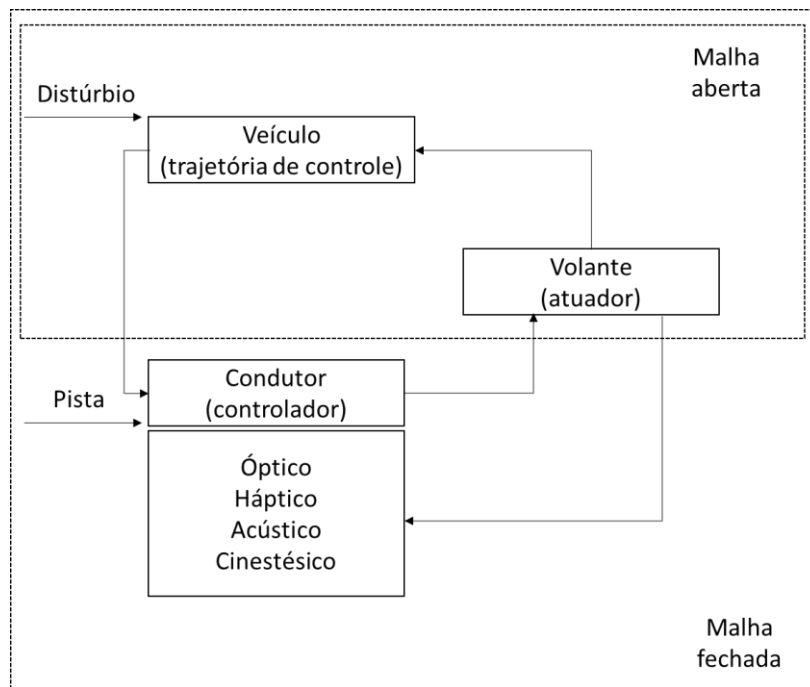
A fase descendente do “V” consiste na definição inicial das macro características desejadas, tais como autonomia, conforto e resposta direcional. Alguns desses requisitos são qualitativos, exigindo que, nas etapas subsequentes, sejam definidos requisitos quantitativos para garantir seu atingimento. Posteriormente, o sistema é subdividido em subsistemas e componentes específicos, cada qual desenvolvido ou selecionado visando ao atendimento dos requisitos pré-estabelecidos.

A fase ascendente do “V” envolve o processo de verificação e validação dos sistemas e componentes desenvolvidos, assegurando o cumprimento dos objetivos iniciais. Neste contexto, destaca-se a verificação dos requisitos relacionados à dinâmica veicular, como estabilidade direcional e esforço no volante, que são fundamentais para assegurar uma experiência de direção satisfatória e segura.

1.1 Desempenho subjetivo da sensação de direção e resposta do veículo

O comportamento dinâmico lateral do veículo pode ser descrito por um sistema de controle, conforme ilustrado na figura 2. Neste sistema, o motorista atua como controlador, recebendo informações principalmente visuais e táteis, relacionadas ao percurso da pista, à posição do veículo e ao torque percebido no volante. A atuação do motorista ocorre por meio do volante, conferindo ao sistema de direção um papel duplo: como atuador, permitindo ao motorista ajustar a trajetória do veículo, e como sensor, fornecendo informações sobre o estado do veículo. O torque transmitido pelo volante é o *feedback* mais relevante para o condutor, devido ao menor tempo de reação comparado às informações visuais ou acústicas (PFEFFER, 2006).

Figura 2. Sistema de controle Condutor-Veículo



Fonte: Adaptado de (PFEFFER; HARRER; JOHNSTON, 2008).

A dinâmica veicular envolve não apenas aspectos técnicos e objetivos de desempenho, mas também a interação entre o veículo e seus ocupantes. Um veículo de passeio transcende a função de transporte seguro entre dois pontos; trata-se também de uma máquina projetada para proporcionar sensações aos seus ocupantes (GIL GÓMEZ *et al.*, 2015).

Embora critérios objetivos, sejam indispensáveis para o desenvolvimento e aperfeiçoamento dos sistemas veiculares, eles não esgotam a compreensão da dinâmica entre motorista e veículo. A avaliação subjetiva desempenha um papel crucial nessa compreensão, uma vez que aspectos como percepção do torque no volante, sensações táteis e visuais são centrais para a experiência de direção (GIL GÓMEZ *et al.*, 2015). Entretanto, avaliações subjetivas são frequentemente caras e demoradas, pois dependem da construção de protótipos físicos para testes reais. Deste modo, há um apelo para que durante a etapa de projeto de um veículo, as percepções subjetivas do condutor possam ser previstas adequadamente com auxílio de simulações (GIL GÓMEZ *et al.*, 2015). Neste contexto, ferramentas que auxiliem a definição precisa dos requisitos de desempenho (métricas), bem como a antecipação da verificação do cumprimento dos objetivos qualitativos, constituem um diferencial significativo na indústria automotiva.

1.2 Simuladores de direção

Os simuladores de direção destacam-se como ferramentas que oferecem a possibilidade de avaliar o desempenho dinâmico do veículo como, estabilidade direcional, capacidade de manobra e conforto do condutor em um ambiente virtual controlado, já nas etapas iniciais do desenvolvimento. Tal abordagem favorece a identificação precoce de melhorias e ajustes necessários, contribuindo para a qualidade e eficiência no desenvolvimento do produto. Essas ferramentas têm sido utilizadas desde o início da década de 1970, desde então, avanços tecnológicos significativos em capacidade computacional, processamento gráfico e sistemas de realidade virtual ampliaram seu potencial e aplicação (GRUENING *et al.*, 1998). Estes simuladores são sistemas baseados em *software* capazes de replicar virtualmente a experiência de condução de veículos. Tornaram-se cada vez mais difundidos tanto na indústria automotiva quanto em pesquisas acadêmicas, sendo constituídos principalmente por modelos de dinâmica veicular, sistemas de movimento e ambientes virtuais, que interagem para produzir uma experiência de direção realista (BRUCK; HAYCOCK; EMADI, 2021).

As aplicações dos simuladores de direção abrangem estudos focados no motorista, projetos de chassis e *powertrain*, além do desenvolvimento de sistemas autônomos. Devido à segurança proporcionada e ao custo reduzido, espera-se que seu uso aumente significativamente no futuro,

consolidando-se como ferramenta essencial para testes de desempenho veicular e comportamento humano (BRUCK; HAYCOCK; EMADI, 2021). A eficácia desses simuladores depende da capacidade de reproduzir com precisão a física do veículo e sua interação com a pista, bem como do ambiente em torno do veículo. Além disso, é fundamental permitir que o condutor interprete adequadamente o estado do modelo por meio de estímulos visuais, auditivos e cinestésicos, além de interagir com controles realistas, como volante e pedais (GRUENING *et al.*, 1998).

Entre as vantagens mais notáveis do uso de simuladores está a segurança, já que testes podem ser realizados sem riscos físicos. Outras vantagens incluem a capacidade de replicar precisamente cenários e condições, possibilitando a repetição exata de testes, a facilitação da coleta de dados e a rápida troca entre diferentes modelos veiculares e ambientes simulados. Entretanto, ressalta-se a importância de garantir a correspondência precisa entre o modelo simulado e o cenário real, evitando a geração de informações incorretas ou enganosas (GRUENING *et al.*, 1998).

Estudos recentes têm explorado o uso de simuladores de direção em diferentes contextos de desenvolvimento veicular. Barbosa (2022) evidenciou que a integração de modelos com avaliações subjetivas em simulador possibilita análises mais consistentes do sistema de direção, com métricas como on-center feel, continuidade de torque e retorno do volante apresentando boa correlação com a percepção dos pilotos. O estudo mostrou ainda que o simulador amplia as possibilidades de desenvolvimento, permitindo reduzir custos e tempo de prototipagem física, além de retroalimentar o processo de simulação com informações relevantes para direcionar esforços de projeto. Carneiro (2019) destacou a relevância do simulador de dinâmica veicular para a avaliação do comportamento dinâmico, ao demonstrar que a correlação entre resultados objetivos e subjetivos é essencial para capturar fenômenos não identificáveis apenas por meio de simulações numéricas. O estudo mostrou que aspectos como a não linearidade do subesterço e a variação do apoio com a aceleração lateral só podem ser analisados em ambiente de simulação, evidenciando o papel do simulador na identificação de efeitos sutis. Leal (2024) demonstrou a viabilidade de empregar simuladores dinâmicos já na fase de concepção de projetos, propondo um fluxo metodológico em que análises sensoriais e numéricas permitem otimizar a geometria e o cinematismo de suspensão e direção antes da construção de protótipos. O estudo destacou que pilotos experientes conseguem

identificar com precisão variações geométricas em avaliações cegas, reforçando a coerência entre percepções subjetivas e alterações reais no comportamento veicular.

Apesar dos benefícios dessas ferramentas, correlações precisas entre métricas objetivas e avaliações subjetivas permanecem necessárias para aproveitar plenamente suas vantagens. Portanto, compreender profundamente essas correlações é um passo fundamental para otimizar o desempenho e a sensação de direção sem depender exclusivamente de protótipos físicos, acelerando e tornando mais eficiente o processo de desenvolvimento veicular (GIL GÓMEZ *et al.*, 2015).

1.3 Aprendizado De Máquina

Para lidar com a complexidade associada ao grande número de métricas objetivas e facilitar a identificação de padrões nas correlações entre essas métricas e avaliações subjetivas, propõe-se a aplicação de métodos de aprendizado de máquina.

O uso de técnicas de aprendizado de máquina tem se mostrado cada vez mais presente na análise da dinâmica veicular. Um modelo para estimativa das variáveis de estado a partir de sinais básicos é proposto por Li *et al.* (2025), é considerada uma abordagem que integra modelos físicos com redes neurais de aprendizado profundo. É utilizado um método de regressão para estabelecer uma relação linear entre os estados estimados e sinais dos sensores, a fim de evitar a necessidade de derivação do modelo físico. A rede neural é então empregada para capturar dinâmicas residuais, permitindo uma fusão entre conhecimento físico sobre o modelo e aprendizado de máquina. O modelo é validado por simulações de um veículo e apresenta bons resultados quando comparado ao modelo físico. Similarmente, Fang e Yu (2024) apresentam um método parecido para estimar as variáveis de estado de um veículo autônomo de corrida em escala reduzida.

Hermansdorfer *et al.* (2020) empregam redes neurais estritamente baseadas em dados, sem apoio direto de modelos físicos. Um exemplo envolve redes neurais recorrentes que superaram o modelo de bicicleta na descrição de efeitos de maior ordem sem a necessidade de modelar o sistema.

Em Pan *et al.* (2023) diferentes técnicas de aprendizado de máquina foram avaliadas para estimar parâmetros específicos, como a rigidez e o amortecimento da suspensão com base nas variáveis de estado do veículo. Foram testados os modelos GRNN, FNN, PSO-BP, RBF e Elman. Dentre eles, os modelos PSO-BP, RBF e Elman apresentaram os melhores desempenhos.

Algumas investigações estendem o uso do aprendizado de máquina para a segurança ativa e monitoramento de fatores de risco na direção. Em um desses estudos, adotou-se uma rede neural recorrente com análise bidirecional e mecanismo de atenção para detectar comportamentos de distração relacionados ao uso de telefone celular, alcançando precisão elevada na identificação de tais eventos a partir dos sinais do veículo (WANG *et al.*, 2022).

A aplicação do método GRNN para mapear similaridades entre diferentes veículos e prever a percepção de dirigibilidade com base em métricas quantitativas é apresentada em Gil Gómez *et al.* (2018). No contexto do estudo os veículos são agrupados por similaridade utilizando o algoritmo SOM (da sigla em inglês, *Self Organizing Maps*), após a criação do mapa é gerada uma superfície de regressão com uma rede neural que permite a visualização do desempenho subjetivo de acordo com a região em que o veículo está posicionado no mapa.

Este estudo se propõe a realizar simulações para obtenção de métricas objetivas que caracterizem a sensação de direção e a resposta direcional de um conjunto de veículos de diferentes classes e fabricantes, utilizar um simulador de direção com base móvel para obter avaliações subjetivas destes veículos e aplicar análise estatística e métodos de aprendizado de máquina para prever o desempenho subjetivo de um veículo com base em suas métricas objetivas. Tal metodologia permite ainda realizar estudos de sensibilidade para avaliar como as variações nas métricas objetivas podem influenciar as percepções subjetivas, facilitando o ajuste e refinamento dos requisitos.

1.4 Objetivo geral

O objetivo deste trabalho é desenvolver uma rede neural artificial capaz de prever o desempenho subjetivo de resposta direcional e sensação de direção de um veículo com base em suas métricas de dinâmica veicular lateral obtidas em manobras de malha aberta.

1.5 Objetivos específicos

Nesse trabalho de pesquisa, definem-se os seguintes objetivos específicos:

- Obter dados objetivos de dinâmica veicular lateral e de sensação de direção de diversos veículos, de diferentes seguimentos, através de simulações
- Agrupar veículos por similaridade de suas métricas
- Obter dados subjetivos da sensação de direção dos veículos supracitados em simulador de direção
- Determinar os parâmetros objetivos com maior importância sobre a qualidade da sensação de direção


2. REVISÃO BIBLIOGRÁFICA

Nesta seção são apresentados os conceitos fundamentais que embasam o estudo do comportamento dinâmico lateral e do sistema de direção em veículos automotivos. Inicialmente, define-se o sistema de coordenadas empregado para descrever as movimentações e forças às quais o veículo é submetido. Na sequência, são discutidas as características geométricas da suspensão e sua importância para a dinâmica veicular, abordando aspectos específicos das vistas frontal e lateral do montante, bem como os fundamentos da geometria de Ackerman. São abordadas as propriedades mecânicas dos pneus e sua influência direta sobre o comportamento direcional dos veículos, destacando especialmente o conceito de gradiente de subesterço. Por fim, a revisão traz uma discussão sobre conceitos relacionados ao aprendizado de máquina, abordando o processo geral de aplicação dessas técnicas.

2.1 Definição do sistema de coordenadas

O sistema de referência adotado para análise das acelerações, velocidades e deslocamentos do veículo é comumente subdividido em coordenadas fixas e coordenadas móveis (fixadas ao veículo). O sistema móvel possui sua origem fixada no centro de gravidade do veículo, movendo-se juntamente com ele, enquanto o sistema de coordenadas fixo à terra apresenta sua origem em um ponto arbitrário, geralmente orientado de forma consistente com o sistema móvel no instante inicial da análise. Parâmetros relacionados à trajetória do veículo são calculados em relação ao referencial fixo, ao passo que as movimentações da carroceria são calculadas no referencial móvel. O sistema de coordenadas utilizado neste estudo é representado pela figura 3.

Figura 3. Sistema de coordenadas



Fonte: Elaboração pelo autor (2025).

Onde:

- x representa o eixo longitudinal, do sistema de coordenadas móvel, direcionado para trás do veículo;
- y é o eixo lateral, do sistema de coordenadas móvel, direcionado para a direita do veículo;
- z é o eixo vertical, do sistema de coordenadas móvel, orientado para cima a partir do plano horizontal do veículo.
- X , Y e Z representam o sistema fixo.

Além dessas direções principais, três movimentos rotacionais também são definidos em torno dos eixos do sistema de coordenadas móvel:

- Rolagem (*rolagem*), representando a rotação em torno do eixo longitudinal x ;
- Arfagem (*Pitch*), representando a rotação em torno do eixo lateral y ;
- Guinada (*Yaw*), representando a rotação em torno do eixo vertical z .

2.2 Geometria de suspensão

O montante é o componente responsável pela ligação das rodas aos sistemas de suspensão, freios e direção, sua distribuição geométrica define parâmetros grande importância que afetam todos estes subgrupos. Esses parâmetros serão abordados nas sessões subsequentes, dada sua importância para a sensação de direção do veículo.


2.2.1 Vista frontal do montante

O eixo do pino mestre (*kingpin*) é definido pelos pontos de pivoteamento do montante nos braços da suspensão. Ao prolongar-se o eixo do pino mestre até o solo, gera-se, no plano frontal, uma distância horizontal entre este ponto de prolongamento e o ponto central de contato do pneu com a pista, denominada *scrub radius*. Esse parâmetro influencia diretamente a percepção do condutor quanto às acelerações longitudinais aplicadas ao veículo.

A inclinação do pino mestre, medida no plano frontal do veículo, desempenha diversas funções essenciais para o desempenho dinâmico veicular. Sua principal função está relacionada à otimização do espaço para o empacotamento dos componentes do montante e da roda. Uma inclinação insuficiente do pino mestre resulta em valores elevados de *scrub radius*, causando instabilidade direcional quando o veículo é submetido a cargas longitudinais. Adicionalmente, a inclinação do pino mestre afeta a variação do ângulo de câmbor durante o esterçamento das rodas (MILLIKEN; MILLIKEN, 1994).

Outro parâmetro geométrico importante é o *spindle length*, definido como a distância horizontal entre o eixo do pino mestre e um eixo paralelo que atravessa o centro da roda. Este parâmetro gera uma elevação do veículo ao esterçar as rodas, aumentando o torque necessário no volante e contribuindo para um efeito auto-alinhante em manobras de baixa velocidade. A figura 4 representa o pino mestre e os ângulos e distâncias formados por ele no plano frontal do veículo.

Figura 4. Vista frontal do montante.



Fonte: Elaboração pelo autor (2025).

2.2.2 Vista lateral do montante


Quando analisado em uma vista lateral do veículo, o eixo do pino mestre (*kingpin*) forma um ângulo com a linha vertical denominado ângulo de cáster. Ao prolongar-se o eixo do pino mestre até o solo nesta perspectiva, gera-se uma distância longitudinal em relação ao centro da roda conhecida como *mechanical trail*. Este parâmetro geométrico exerce influência direta na percepção do motorista quanto às forças laterais e aos momentos auto-alinhantes gerados na interface pneu-pista durante manobras.

O ângulo de cáster induz também um deslocamento vertical da roda ao realizar-se o esterçamento, o que influencia diretamente na variação do ângulo de câmbor da roda durante manobras. É possível ajustar o valor do *mechanical trail* sem modificar o ângulo de cáster, por meio da introdução de um deslocamento longitudinal (*cáster offset*) do eixo do pino mestre em relação ao centro da roda,

oferecendo maior flexibilidade no ajuste das características de direção e estabilidade do veículo (MILLIKEN; MILLIKEN, 1994). Conforme apresentado na figura 5.

Na vista lateral do montante pode-se definir ainda a alavanca de direção, seu comprimento e posição determinam a conversão do movimento translacional da cremalheira em movimento rotacional em torno do eixo do *kingpin*. O comprimento da alavanca de direção tem influência direta na razão de direção, que se define como ângulo de entrada no volante por ângulo médio de saída nas rodas ao se esterçar.

Figura 5. Vista lateral do montante.




Fonte: Elaboração pelo autor (2025).

2.2.3 Geometria de Ackerman

Os ângulos ideais de esterçamento das rodas dianteiras, considerando o comportamento direcional do veículo em baixa velocidade, no qual os pneus não geraram forças laterais significativas e, portanto, rolam praticamente sem ângulo de deriva, podem ser obtidos por meio da geometria de

Ackerman. A geometria de Ackerman, embora tenha pouca influência na resposta direcional em velocidades mais elevadas, pode afetar significativamente os momentos auto-alinhantes do sistema de direção em baixa velocidade, alterando o retorno do volante à posição central e a sensação de direção proporcionada ao condutor (GILLESPIE, 2021). A figura 6 representa a geometria, que se define pelo ponto de encontro das retas perpendiculares ao plano X-Z dos pneus, denominado centro de giro. A distância deste ponto ao centro de gravidade do veículo determina o raio da curva.

Figura 6. Geometria de Ackerman.



Fonte: Adaptado de (GILLESPIE, 2021).

Onde:

- δ_i é o esterçamento da roda interna [°]
- δ_o é esterçamento da roda externa [°]
- L é a distância Entre eixos [m]
- t é a Bitola traseira [m]
- R = Raio [m]

Com isso são obtidas a equação 1 e a equação 2, que representam os ângulos de esterçamento das rodas:

$$\delta_o = \tan^{-1} \frac{L}{R + \frac{t}{2}} \quad (1)$$

$$\delta_i = \tan^{-1} \frac{L}{R - \frac{t}{2}} \quad (2)$$

Considerando a linearização de ângulos pequenos, define-se δ como o valor médio entre as rodas dianteiras, obtido através da equação 3:


$$\delta = \frac{L}{R} \quad (3)$$

O esterçamento médio das rodas dianteiras é um importante parâmetro para a definição e quantificação dos conceitos de subesterço e sobresterço.

2.3 Propriedades mecânicas dos pneus

Durante a realização de curvas, o equilíbrio do veículo é influenciado pela presença de aceleração lateral, a qual deve ser compensada pelo desenvolvimento de forças laterais nos pneus. Para gerar essas forças, os pneus experimentam deslizamento lateral, resultando no ângulo de deriva (α), que corresponde à diferença entre a direção real de deslocamento do pneu e a direção para onde ele está apontado (GILLESPIE, 2021). A representação do ângulo de deriva é apresentada na figura 7.

Figura 7. Ângulo de Deriva.



Fonte: Adaptado de (GILLESPIE, 2021).

A força lateral gerada pelo pneu (F_y), cresce com o aumento do ângulo de deriva, durante um intervalo linear. A relação entre a força lateral e o ângulo de deriva pode ser descrita por um coeficiente denominado rigidez de deriva (C_α), que representa a inclinação da curva de F_y em função de α , de acordo com a equação 4.

$$C_\alpha = \frac{F_y}{\alpha} \quad (4)$$


A rigidez em deriva depende de diversas variáveis, como o tipo e construção do pneu, pressão de inflação e do ângulo de câmbio. Além disso, a magnitude da força lateral também é influenciada pela carga vertical aplicada ao pneu (F_z). Para descrever essa relação, utiliza-se o coeficiente de deriva (CC_α), definido como a rigidez de deriva dividida pela carga sobre o pneu, de acordo com a equação 5. Esse coeficiente geralmente atinge seus maiores valores sob cargas leves e diminui conforme a carga aplicada ao pneu se aproxima do seu valor nominal.

$$CC_\alpha = \frac{C_\alpha}{F_z} \quad (5)$$

2.4 Gradiente de subesterço

A análise do comportamento do veículo em curvas em regime permanente pode ser realizada a partir das equações derivadas da Segunda Lei de Newton, considerando as condições de equilíbrio dinâmico e a geometria do movimento curvilíneo. Para simplificar a formulação matemática, é comum representar o veículo por meio do modelo bicicleta, no qual as rodas dianteiras são substituídas por uma única roda equivalente com um ângulo de esterçamento δ , e as rodas traseiras são igualmente representadas por uma única roda (GILLESPIE, 2021). Essa abordagem quando o raio da curva é significativamente maior do que a distância entre os eixos do veículo, permitindo a consideração de pequenos ângulos de deriva e a negligência das diferenças de ângulo entre as rodas internas e externas na curva. O modelo de bicicleta é apresentado na figura 8.

Figura 8. Modelo de Bicicleta.



Fonte: (GILLESPIE, 2021).

Onde:

- δ é o esterçamento médio das rodas dianteiras [°]
- α_d é o ângulo de deriva do eixo dianteiro [°]
- α_t é o ângulo de deriva do eixo traseiro [°]
- L é a distância Entre eixos [m]
- b é a distância do eixo dianteiro ao centro de gravidade do veículo [m]
- c é a distância do eixo traseiro ao centro de gravidade do veículo [m]
- t é a Bitola traseira [m]
- R = Raio de curvatura [m]

Para uma dada velocidade e raio de curva, a soma das forças laterais geradas pelos pneus deve ser igual ao produto da massa do veículo pela aceleração centrípeta. Além disso, para que o veículo permaneça em equilíbrio de momentos em torno do centro de gravidade, as forças laterais nos eixos dianteiro e traseiro devem obedecer a uma relação proporcional à distribuição de carga nos eixos. Assim, a força lateral desenvolvida no eixo traseiro é proporcional ao peso sobre esse eixo, enquanto a força lateral no eixo dianteiro segue a mesma relação com a carga suportada pelas rodas dianteiras. A equação 6, é obtida através da adição da contribuição dos ângulos de deriva dos eixos dianteiro e traseiro à equação 3. Os ângulos de deriva nas rodas dianteira e traseira podem ser determinados, de acordo com a equação 7 e com a equação 8, respectivamente.

$$\delta = \frac{L}{R} + \left(\frac{W_d}{C_{ad}} - \frac{W_t}{C_{at}} \right) \frac{V^2}{gR} \quad (6)$$

$$\alpha_d = \frac{W_d}{C_{ad}} \quad (7)$$

$$\alpha_t = \frac{W_t}{C_{at}} \quad (8)$$

A relação entre o ângulo de esterçamento do veículo e o raio da curva é um fator determinante para caracterizar sua resposta direcional. Esse comportamento é descrito pelo gradiente de subesterço (KUG), um parâmetro que expressa a variação do ângulo de esterçamento em função da aceleração lateral. O gradiente de subesterço, equação 9, é definido como a diferença entre as razões da carga nos eixos dianteiro e traseiro pela respectiva rigidez em deriva dos pneus.

$$KUG = (\alpha_d - \alpha_t) \frac{V^2}{gR} \quad (9)$$

Dependendo do valor desse gradiente, o veículo pode apresentar três regimes distintos de comportamento direcional. No caso de um veículo neutro ($KUG=0$), os ângulos de deriva nas rodas dianteiras e traseiras são iguais ($\alpha_d = \alpha_t$), o que significa que, ao realizar uma curva de raio constante, não há necessidade de correção do ângulo de esterçamento conforme a velocidade aumenta. Nesse regime, o ângulo de esterçamento necessário para manter a trajetória equivale ao ângulo de Ackerman, definido pelas dimensões do veículo. Já no caso de um veículo subesterçante ($KUG > 0$), a relação entre carga e rigidez em deriva dos pneus no eixo dianteiro é maior do que no eixo traseiro ($\alpha_d > \alpha_t$), isso faz com que, à medida que a aceleração lateral aumenta, o ângulo de deriva das rodas dianteiras seja superior ao das traseiras. Como consequência, para manter o raio da curva constante, o motorista precisa aumentar o ângulo de esterçamento com a velocidade. Por outro lado, quando o veículo apresenta sobresterço ($KUG < 0$), a relação entre carga e rigidez em deriva no eixo traseiro é maior do que no dianteiro. Nesse caso, o ângulo de deriva das rodas traseiras supera o das dianteiras ($\alpha_d < \alpha_t$), fazendo com que, ao aumentar a velocidade em uma curva de raio constante, o ângulo de esterçamento necessário seja reduzido.

Dois outros conceitos importantes são velocidade crítica e velocidade característica. Velocidade crítica é aquela em que, para um veículo sobresterçante, o ângulo de volante necessário para negociar uma curva é igual a zero (i.e., a própria relação entre os ângulos de deriva dianteiros e traseiros é suficiente para manter o veículo na trajetória circular). Já a velocidade característica é aquela que, para um veículo subesterçante, o ângulo de volante necessário para negociar uma curva é o dobro daquele da geometria de Ackerman.

2.5 Aprendizado de máquina

O aprendizado de máquina é uma área da inteligência artificial que visa desenvolver algoritmos capazes de melhorar seu desempenho automaticamente, adaptando-se com base em experiências prévias ou dados fornecidos. Seu princípio fundamental envolve permitir que um computador ajuste suas ações para torná-las mais precisas, onde essa precisão é avaliada pela capacidade do algoritmo em produzir resultados próximos daqueles considerados corretos. Assim, algoritmos de aprendizado de máquina buscam generalizar padrões identificados em conjuntos de dados para realizar previsões ou tomar decisões em novas situações (MARSLAND, 2014).

O aprendizado supervisionado é o método mais comum e consiste em fornecer ao algoritmo um conjunto de treinamento contendo exemplos com as respostas corretas já conhecidas (*targets*). A partir desses exemplos, o algoritmo aprende a generalizar, sendo capaz de fornecer respostas corretas para novas entradas ainda não vistas (MARSLAND, 2014).

Diferentemente do método supervisionado, no aprendizado não-supervisionado, as respostas corretas não são fornecidas previamente. O algoritmo tenta identificar similaridades e padrões entre os dados de entrada, agrupando automaticamente elementos semelhantes sem uma orientação prévia explícita. Na abordagem estatística, esse método é conhecido como estimativa de densidade (MARSLAND, 2014).

2.5.1 O processo de aplicação do aprendizado de máquina

Segundo Marsland (2014), o processo de aplicação de aprendizado de máquina inicia-se com a coleta e preparação dos dados. O autor ressalta que a seleção adequada das variáveis (*features*) é fundamental para o sucesso do aprendizado de máquina. Isso envolve identificar quais informações são mais úteis para resolver o problema específico em questão.

Segundo Marsland (2014), à medida que a quantidade de variáveis aumenta, a densidade de dados no espaço disponível diminui rapidamente, dificultando a identificação de padrões e correlações. Esse fenômeno ocorre porque, ao elevar-se o número de dimensões, a partir de certo ponto o

volume da região que contém os dados se torna cada vez menor, tendendo a zero quando o número de dimensões é muito alto. Tal fenômeno, limita a aplicação de algoritmos baseados na distância euclidiana.

Por essa razão, Marsland (2014), enfatiza a importância da redução da dimensionalidade das variáveis analisadas, como estratégia para minimizar esse efeito. Tal procedimento requer conhecimento prévio sobre os dados, permitindo selecionar variáveis relevantes para assegurar que os algoritmos de aprendizado de máquina recebam entradas eficientes, evitando, assim, um desempenho comprometido pelo excesso de dimensões.

Posteriormente, ocorre a escolha dos algoritmos mais apropriados, considerando as particularidades dos dados e o tipo específico de tarefa a ser resolvida, como classificação, regressão ou agrupamento. Muitos dos métodos de aprendizado de máquina exigem ainda uma etapa adicional de ajuste fino de parâmetros, que são definidos com base em testes ou métodos de otimização, visando melhorar o desempenho geral do modelo (MARS LAND, 2014).

Uma vez definidos os dados, o algoritmo e os parâmetros ideais, segue-se a fase de treinamento, onde o algoritmo usa o conjunto disponível para construir um modelo preditivo capaz de generalizar seu desempenho para dados novos. Marsland (2014), destaca a importância da avaliação criteriosa do modelo construído. Essa avaliação é feita com dados não utilizados durante o treinamento, permitindo medir a capacidade do modelo de prever corretamente resultados em situações reais.

Conforme descrito por Marsland (2014), o principal objetivo do aprendizado de máquina é gerar modelos capazes de prever corretamente as saídas para dados novos, sejam eles classificações discretas ou valores contínuos. Assim, uma etapa crucial desse processo consiste em avaliar a capacidade preditiva do modelo, medindo o quanto suas previsões se aproximam das respostas corretas já conhecidas. Uma forma inicial e simples de avaliação consiste em medir o erro diretamente sobre os dados utilizados durante o treinamento. Contudo, esse procedimento não fornece uma visão precisa da capacidade do modelo em generalizar seu desempenho para novos dados, uma vez que o objetivo final é garantir que o modelo seja eficaz em situações inéditas.

Normalmente divide-se o conjunto total de dados em subconjuntos específicos: um conjunto de treinamento, utilizado exclusivamente para ajustar os parâmetros do modelo; um conjunto de teste, empregado para avaliar o desempenho final do modelo após o treinamento; e, ainda, um terceiro conjunto, denominado de validação, utilizado para monitorar o desempenho intermediário do modelo durante o processo de treinamento.

A inclusão do conjunto de validação é necessária para detectar e prevenir o fenômeno conhecido como sobreajuste (*overfitting*), no qual o modelo torna-se excessivamente ajustado aos dados de treinamento, reduzindo sua capacidade de generalizar corretamente para novos casos. Em contrapartida, um treinamento insuficiente (*underfitting*) gera modelos demasiadamente simples, incapazes de capturar adequadamente os padrões presentes nos dados.

2.5.2 Coeficiente de correlação de Pearson

O coeficiente de correlação de Pearson, r_{xy} , é calculado pela equação 10:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (10)$$

Onde:

- r_{xy} é o coeficiente de correlação de Pearson entre as variáveis x e y ,
- x_i e y_i representam os valores das variáveis x e y para a observação i ,
- \bar{x} e \bar{y} são as médias das variáveis x e y ,
- n é o número total de observações.

2.5.3 Normalização dos dados

A preparação adequada dos dados, por meio de transformações como a normalização, é fundamental para melhorar a eficiência do aprendizado em algoritmos de *machine learning*. A escala dos dados de entrada e saída para o intervalo entre 0 e 1, independentemente da função de

ativação utilizada, contribui para evitar o crescimento excessivo dos pesos e, conseqüentemente, favorece a estabilidade e o desempenho do modelo (MARSLAND, 2014).

A transformação é dada pela equação 11:

$$X_{normalizado} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (11)$$

Onde:

- X representa o valor original da variável,
- X_{min} é o valor mínimo da variável no conjunto de dados,
- X_{max} é o valor máximo da variável no conjunto de dados,
- $X_{normalizado}$ é o valor da variável após a normalização.

2.5.4 Redução da dimensionalidade

A Análise de Componentes Principais (PCA, do inglês *Principal Components Analysis*) é um método estatístico que visa identificar direções no espaço das variáveis originais que expliquem a maior parte da variabilidade do conjunto de dados (MARSLAND, 2014). O procedimento metodológico envolve as seguintes etapas principais:

Inicialmente, as N amostras originais, representadas por vetores $x_i = (x_{1i}, x_{2i}, \dots, x_{Mi})$, são organizadas em uma matriz de dados X de dimensão $N \times M$, em que N corresponde ao número de observações e M ao número de variáveis observadas.

Posteriormente, realiza-se a centralização dos dados, subtraindo-se a média de cada coluna (variável), obtendo-se assim uma nova matriz B , cujos elementos refletem a variação dos dados em torno do valor médio.

Com os dados centralizados, calcula-se a matriz de covariância C de acordo com a equação 12:

$$C = \frac{1}{N} B^T B \quad (12)$$

Esta matriz quantifica as relações lineares existentes entre as variáveis originais.

Em seguida, procede-se à decomposição espectral da matriz de covariância C , que consiste na identificação de seus autovalores e autovetores. Formalmente, determina-se uma matriz de autovetores V e uma matriz diagonal de autovalores D , que satisfazem a relação apresentada na equação 13:

$$V^{-1} C V = D \quad (13)$$

Os autovetores contidos em V representam as direções principais dos dados, enquanto os elementos diagonais da matriz D (autovalores) indicam a magnitude da variabilidade capturada por cada componente principal.

Os componentes são então ordenados de acordo com a magnitude decrescente dos autovalores correspondentes, priorizando aqueles que explicam maior parcela da variância total. Este ordenamento é aplicado tanto à matriz de autovalores D quanto à matriz de autovetores V .

Por fim, componentes com autovalores inferiores a um limiar pré-definido η são descartados, resultando em uma redução dimensional do conjunto de dados original. Após este procedimento, obtém-se um conjunto reduzido de L dimensões principais que retêm grande parte da informação original, porém com um menor número de variáveis.

2.5.5 K-Means

O *K-Means* é um algoritmo iterativo que busca particionar os dados em k grupos distintos (*clusters*), de forma que as observações dentro de um mesmo grupo sejam mais similares entre si do que com as de outros grupos (MARS LAND, 2014).

Este algoritmo é descrito pelas seguintes etapas:

Inicialmente, escolhe-se um número de clusters desejados e define-se aleatoriamente posições iniciais dos centros dos *clusters* no espaço das variáveis, μ_j . Em seguida, realiza-se um procedimento iterativo com duas etapas principais.

Para cada observação, calcula-se a distância em relação a cada um dos centros de *cluster*, atribuindo-se a observação ao cluster com o centro mais próximo, definido pela distância mínima, de acordo com a equação 14.

$$d_i = \min_j d(x_i, \mu_j) \quad (14)$$

Atualizam-se as posições dos centros de cluster para a média aritmética das observações atribuídas a cada *cluster*, de acordo com a equação 15.

$$\mu_j = \frac{1}{N_j} \sum_{i=1}^{N_j} x_i \quad (15)$$

Essas etapas são repetidas até que os centros dos *clusters* não apresentem mudanças significativas em suas posições, indicando convergência.

2.5.5.1 Regressão linear

A regressão linear busca estabelecer uma relação linear entre as variáveis independentes e a variável dependente. O modelo é representado pela equação 16:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (16)$$

Onde:

- y é a variável dependente
- x_1, x_2, \dots, x_n são as variáveis independentes
- $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ são os coeficientes do modelo
- ε é o termo de erro

Os coeficientes são estimados minimizando a soma dos quadrados dos resíduos. Entre o valor observado e o valor predito pelo modelo.

2.5.5.2 Regressão ridge

A regressão Ridge é uma extensão da regressão linear que adiciona um termo de regularização para lidar com problemas de multicolinearidade e sobreajuste. A função objetivo a ser minimizada é apresentada na equação 17:

$$\min \Sigma (y_i - \hat{y}_i)^2 + \alpha \Sigma \beta_n^2 \quad (17)$$

Onde α é o parâmetro de regularização que controla a intensidade da penalização. Valores maiores de α resultam em coeficientes menores.

2.5.5.3 K-Nearest Neighbors

O algoritmo *K-Nearest Neighbors* (KNN) é um método não-paramétrico que realiza previsões com base na similaridade entre exemplos. Para um novo ponto x , o valor predito é calculado como a média dos valores dos k vizinhos mais próximos, de acordo com a equação 18:

$$\hat{y}(x) = \frac{1}{k} \Sigma y_i \quad (18)$$

Para os k vizinhos mais próximos de x a distância entre pontos é calculada pela distância euclidiana, conforme a equação 19:

$$d(x_i, x_j) = \sqrt{\sum (x_i^m - x_j^m)^2} \quad (19)$$

Onde x_i^m representa o valor da m-ésima característica do ponto x_i .

2.5.5.4 Random Forest

O algoritmo *Random Forest* fundamenta-se no princípio de que múltiplas árvores de decisão podem superar o desempenho de uma única árvore, desde que exista variedade suficiente entre elas, a predição final é obtida através do voto majoritário para problemas de classificação ou da média das respostas para problemas de regressão (MARSLAND, 2014).

Para um problema de regressão, a predição final é a média das predições individuais das árvores, de acordo com a equação 20:

$$\hat{y} = \frac{1}{T} \sum T_{t(x)} \quad (20)$$

onde $T_{t(x)}$ é a predição da t-ésima árvore para o ponto x , e T é o número total de árvores.

2.5.6 Redes neurais artificiais

O treinamento de redes neurais artificiais pode ser realizado através de diferentes paradigmas de aprendizado, sendo o aprendizado supervisionado uma das abordagens mais amplamente utilizadas. Neste paradigma, o sistema aprende por meio de exemplos rotulados que estabelecem correspondências entre entradas específicas e suas respectivas saídas corretas, permitindo que a rede desenvolva a capacidade de generalização necessária para realizar predições precisas em dados não observados durante o processo de treinamento (MARSLAND, 2014). Esta abordagem é particularmente eficaz em tarefas onde se dispõe de conjuntos de dados com pares entrada-saída

bem definidos, possibilitando que a rede neural ajuste seus parâmetros internos para minimizar o erro entre as predições e os valores esperados.

A rede neural artificial consiste em uma arquitetura com múltiplas camadas de elementos (neurônios) conectados. A propagação do sinal através da rede é descrita pelas equações 21 a 26:

$$z^1 = W^{(1)}x + b^1 \quad (21)$$

$$a^1 = \sigma(z^1) \quad (22)$$

Para as camadas ocultas subsequentes ($l = 2, \dots, L-1$):

$$z^l = W^{(l)}a^{l-1} + b^l \quad (23)$$

$$a^l = \sigma(z^l) \quad (24)$$

Para a camada de saída:

$$z^L = W^{(L)}a^{L-1} + b^L \quad (25)$$

$$\hat{y} = a^L = \sigma_{output}(z^L) \quad (26)$$

Onde:

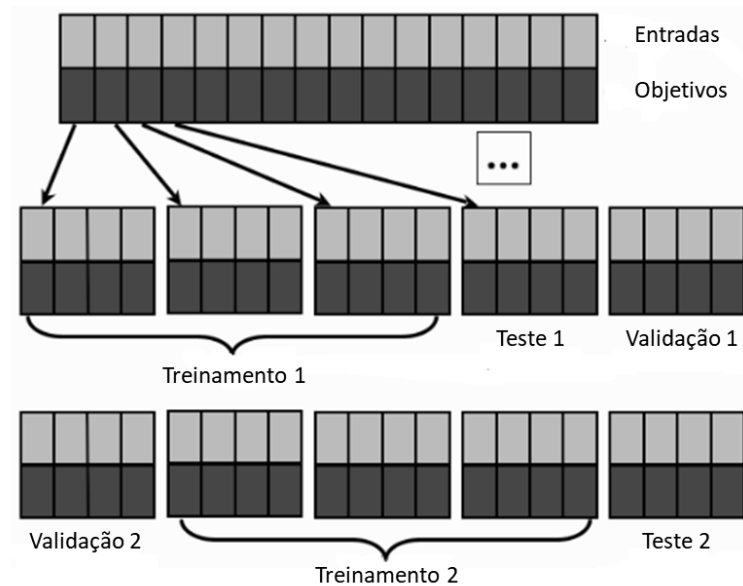
- x é o vetor de entrada
- W^L é a matriz de pesos da l -ésima camada
- b^L é o vetor de viés da l -ésima camada
- z^L é o vetor de ativações lineares da l -ésima camada
- a^L é o vetor de ativações da l -ésima camada após aplicação da função de ativação
- σ é a função de ativação
- σ_{output} é a função de ativação da camada de saída
- \hat{y} é o vetor de saída

O treinamento das redes neurais é realizado minimizando uma função de perda através do algoritmo de otimização.

2.5.7 Validação cruzada

Uma técnica comum de validação é denominada validação cruzada (*cross-validation*), na qual os dados disponíveis são divididos em subconjuntos menores, usados alternadamente como conjuntos de treinamento e validação. Essa técnica, apresentada na figura 9, permite uma avaliação mais robusta do desempenho do modelo quando há uma quantidade limitada de dados disponíveis (MARSLAND, 2014).

Figura 9. Validação Cruzada



Fonte: Adaptado de (MARSLAND, 2014).


O procedimento consiste inicialmente em dividir o conjunto de dados em k subconjuntos (*folds*) de tamanho aproximadamente igual. Em seguida, para cada *fold* i variando de 1 até k , executa-se um processo iterativo onde o modelo é treinado usando todos os *folds* exceto o i -ésimo como conjunto de treinamento, e posteriormente avaliado no i -ésimo *fold*, que funciona como conjunto de validação. Após completar todas as iterações, calcula-se a média e o desvio padrão das métricas de

desempenho obtidas nos *k folds*, proporcionando uma avaliação mais confiável e estatisticamente robusta do modelo.

2.6 Testes de malha aberta

As normas ISO 4138, ISO 7401 e a ISO 13674, que tratam, respectivamente, da resposta do veículo em regime permanente, transiente e ao centro, estabelecem diretrizes para a condução de ensaios controlados e repetitivos, possibilitando a obtenção de parâmetros objetivos que caracterizam a dinâmica veicular de forma sistemática e comparável entre diferentes veículos. Com base nessas normas, são aplicadas manobras específicas que permitem investigar distintos aspectos da resposta dinâmica dos veículos. A primeira delas, denominada Incremento Lento de Esterçamento (Figura 10), consiste na aplicação de uma entrada em rampa, de baixa inclinação, no ângulo de esterçamento. Essa manobra tem como objetivo principal determinar parâmetros associados à linearidade da resposta veicular em regime permanente, além de fornecer subsídios para a avaliação subjetiva da dirigibilidade, como o torque máximo percebido no volante e o comportamento do veículo próximo ao limite de aderência dos pneus.


Figura 10. Entrada De Volante Incremento Lento de Esterçamento.



Fonte: Elaboração pelo autor (2025).

A segunda manobra, conhecida como Varredura Sinusoidal (Figura 11), aplica uma entrada sinusoidal no ângulo do volante com amplitude constante, suficiente para gerar determinada aceleração lateral em regime estacionário. A frequência da entrada é progressivamente aumentada de 0 Hz até 4 Hz, mantendo-se a velocidade do veículo constante. Essa configuração permite analisar a resposta em frequência do sistema.


Figura 11. Entrada De Volante Varredura Sinusoidal.



Fonte: Elaboração pelo autor (2025).

Por fim, o teste de Entrada Sinusoidal (Figura 12) consiste na aplicação de uma excitação senoidal com frequência fixa e amplitude constante, definida para produzir uma aceleração lateral determinada, em regime estacionário. Tem como principal finalidade a quantificação da resposta e esforço direcional para baixos deslocamentos angulares do volante.

Figura 12. Entrada De Volante Senoidal.



Fonte: Elaboração pelo autor (2025).

3. METODOLOGIA

Nesta seção são detalhados os procedimentos adotados para o planejamento e execução do experimento, visando a avaliação da dinâmica lateral do veículo. Inicialmente, é apresentada a etapa de obtenção dos dados, incluindo a definição das métricas objetivas e da escala subjetiva utilizada nas avaliações. Por fim, são descritos os procedimentos de tratamento dos dados e a seleção dos algoritmos de aprendizado de máquina utilizados, sendo um algoritmo de aprendizado não-supervisionado para o agrupamento dos dados e um algoritmo de aprendizado supervisionado para a previsão do desempenho subjetivo.

3.1 Definição das métricas objetivas

Nesta seção são apresentadas as métricas utilizadas para caracterizar o comportamento dinâmico lateral dos veículos investigados. As métricas foram organizadas de forma a permitir a avaliação em três principais grupos: sensação de direção, resposta direcional do veículo e movimentação da carroceria. A sensação de direção está diretamente associada ao *feedback* percebido pelo condutor, especialmente no torque e deslocamento angular do volante. A resposta direcional, por sua vez, envolve parâmetros relacionados ao comportamento direcional e à trajetória do veículo. Já as métricas associadas à movimentação da carroceria avaliam aspectos relativos à rolagem do veículo durante as manobras. O quadro 1, apresentado a seguir, detalha cada uma dessas métricas, fornecendo suas descrições e unidades de medida.


Quadro 1. Métricas objetivas

Nº	Macro Parâmetro	Métrica	Teste	Unidade
1	Resposta Direcional	Gradiente de subesterço AVOL @ 0,4 g	Incremento Lento de Esterçamento @ 100 km/h	°/g
2	Resposta Direcional	Gradiente de subesterço na Roda @ 0,4 g	Incremento Lento de Esterçamento @ 100 km/h	°/g
3	Resposta Direcional	Gradiente do ângulo de deriva posterior @ 0.4g	Incremento Lento de Esterçamento @ 100 km/h	°/g
4	Resposta Direcional	Límite linear de AY	Incremento Lento de Esterçamento @ 100 km/h	g
5	Resposta Direcional	Tempo de resposta de Taxa de Guinada/AVOL @ 1 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	s
6	Resposta Direcional	Tempo de reposta de Taxa de Guinada/AY @ 1 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	s
7	Resposta Direcional	Tempo de reposta de AY/AVOL @ 1 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	s
8	Resposta Direcional	Ganho Estático de Taxa de Guinada/AVOL @ 0 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	1/s
9	Resposta Direcional	Ganho Dinâmico de Taxa de Guinada/AVOL @ 1 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	1/s
10	Resposta Direcional	Linearidade de Taxa de Guinada/AVOL	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	-
11	Resposta Direcional	Ganho Estático de AY/AVOL @ 0 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	g ^º
12	Resposta Direcional	Ganho Dinâmico de AY/AVOL @ 1 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	g ^º
13	Resposta Direcional	Ganho Dinâmico de Taxa de Guinada/AY @ 1 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	°/sg
14	Rolagem	Gradiente de Rolagem/AY @ 0,5 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	°/g
15	Rolagem	Gradiente de Rolagem/AY @ 1 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	°/g
16	Rolagem	Gradiente de Taxa de Rolagem/AVOL @ 1 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	1/s
17	Esforço de Direção	AY @ TVOL Máximo	Incremento Lento de Esterçamento @ 100 km/h	g
18	Esforço de Direção	TVOL Máximo	Incremento Lento de Esterçamento @ 100 km/h	Nm
19	Esforço de Direção	Amplitude de TVOL para AY = 0,3 g	Incremento Lento de Esterçamento @ 100 km/h	Nm
20	Esforço de Direção	Ganho de TVOL/AVOL no trecho Linear	Incremento Lento de Esterçamento @ 100 km/h	Nm/g
21	Esforço de Direção	Progressão de TVOL Durante a Curva	Incremento Lento de Esterçamento @ 100 km/h	-
22	Esforço de Direção	Tempo de reposta de AVOL/TVOL @ 1 Hz	Varredura Sinusoidal (0-4 Hz) @ 100 km/h - 0,3 g	s
23	Esforço de Direção	Amplitude de TVOL @ AY = 0g	Entrada Sinusoidal @ 60 km/h - 0,2 Hz - 0,25 g	Nm
24	Esforço de Direção	Amplitude de TVOL @ AY = 0g	Entrada Sinusoidal @ 120 km/h - 0,2 Hz - 0,25 g	Nm
25	Esforço de Direção	Ganho de TVOL/AVOL	Entrada Sinusoidal @ 60 km/h - 0,2 Hz - 0,25 g	Nm ^º
26	Esforço de Direção	Ganho de TVOL/AVOL	Entrada Sinusoidal @ 120 km/h - 0,2 Hz - 0,25 g	Nm ^º
27	Resposta Direcional	Ganho de AY/AVOL	Entrada Sinusoidal @ 60 km/h - 0,2 Hz - 0,25 g	g ^º
28	Resposta Direcional	Ganho de AY/AVOL	Entrada Sinusoidal @ 120 km/h - 0,2 Hz - 0,25 g	g ^º
29	Esforço de Direção	Amplitude de TVOL para AVOL=0	Entrada Sinusoidal @ 60 km/h - 0,2 Hz - 0,25 g	Nm
30	Esforço de Direção	Amplitude de TVOL para AVOL=0	Entrada Sinusoidal @ 120 km/h - 0,2 Hz - 0,25 g	Nm
31	Esforço de Direção	Amplitude de TVOL na mudança de direção	Entrada Sinusoidal @ 60 km/h - 0,2 Hz - 0,25 g	Nm
32	Esforço de Direção	Amplitude de TVOL na mudança de direção	Entrada Sinusoidal @ 120 km/h - 0,2 Hz - 0,25 g	Nm

Fonte: Elaboração pelo autor (2025).

No teste denominado Incremento Lento de Esterçamento, são obtidas métricas importantes relacionadas ao comportamento subesterçante. Uma dessas métricas é o gradiente de subesterço medido no volante e na roda, ambos avaliados na aceleração lateral (AY) de 0,4 g e expressos em graus por g. Além disso, avalia-se o ângulo de deriva do eixo traseiro (Alfa Posterior) nessa mesma aceleração lateral. Esses gradientes são obtidos em cada uma das curvas apresentadas na figura 13. Outro parâmetro extraído desse teste é o limite linear de aceleração lateral, que indica até qual nível a resposta do veículo permanece linear.


Figura 13. Métricas De Subesterço.



Fonte: Elaboração pelo autor (2025).

A figura 14 apresenta uma curva típica de TVOL/AY obtida a partir do mesmo procedimento. Dessa, determina-se o torque máximo aplicado ao volante (TVOL máximo), expresso em Nm, e a aceleração lateral associada a este ponto (AY @ TVOL máximo), a amplitude de TVOL para AY igual a 0,3 g, e o ganho de torque por aceleração lateral na faixa linear (entre 0,3 e 0,4 g). A progressão do torque ao longo da curva também é avaliada através da razão entre os ganhos de torque nas faixas de aceleração lateral de 0,5-0,6 g e 0,3-0,4 g.

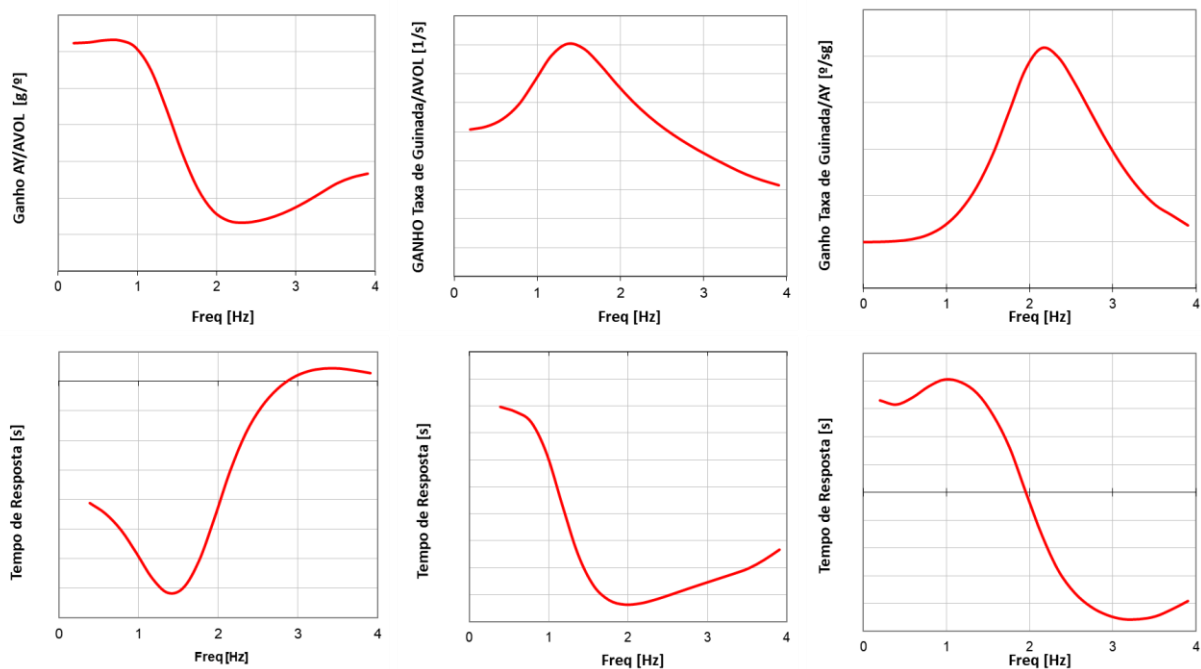
Figura 14. Torque No Volante Por Aceleração Lateral.



Fonte: Elaboração pelo autor (2025).

O teste de Varredura Sinusoidal a 100 km/h e 0,3 g fornece métricas relacionadas à resposta em frequência do veículo. São analisados tempos de resposta entre variáveis, tais como o tempo entre a entrada de ângulo de volante (AVOL) e a resposta em taxa de guinada entre a aceleração lateral e a taxa de guinada, entre o ângulo de volante e a aceleração lateral, todos obtidos a uma frequência de 1 Hz. Ainda nesse procedimento são mensurados ganhos estáticos e dinâmicos, tais como o ganho entre a entrada do ângulo de volante e a taxa de guinada, e entre o ângulo do volante e a aceleração lateral, avaliados em frequências específicas (0 Hz e 1 Hz). A linearidade do ganho entre taxa de guinada e ângulo de volante ao longo da faixa de frequência de 0 a 1 Hz é outra métrica avaliada, conforme apresentado na figura 15.

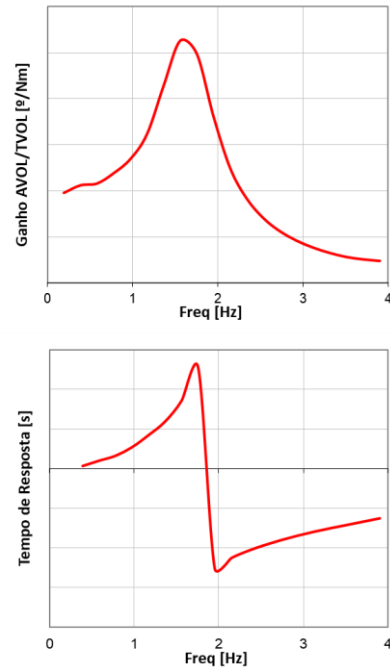
Figura 15. Ganhos e Tempos de Resposta de AY/AVOL, taxa de guinada/AVOL e taxa de guinada/AY.



Fonte: Elaboração pelo autor (2025).

Adicionalmente, avalia-se o tempo de resposta entre o torque aplicado ao volante e a resposta angular do volante a uma frequência de 1 Hz, conforme apresentado na figura 16.


Figura 16. Ganho e Tempo de Resposta de TVOL/AVOL.



Fonte: Elaboração pelo autor (2025).

Com relação ao comportamento de rolagem do veículo, são obtidos gradientes de rolagem em relação à aceleração lateral nas frequências de 0,5 Hz e 1 Hz, além do gradiente da velocidade de rolagem (taxa de rolagem) em relação ao ângulo do volante a 1 Hz, conforme apresentado na figura 17.


Figura 17. Ganhos e Tempos de Resposta de rolagem/ ΔY e taxa de rolagem/ ΔV_{OL} .



Fonte: Elaboração pelo autor (2025).

Testes de Entrada Sinusoidal realizados a 60 km/h e 120 km/h, ambos a 0,2 Hz e 0,25 g, fornecem outros parâmetros importantes para a caracterização dinâmica do veículo. Entre esses parâmetros estão a amplitude do torque no volante para aceleração lateral nula e para ângulo do volante nulo, ganhos de torque por ângulo do volante e ganhos de aceleração lateral por ângulo de volante, e a amplitude do torque do volante durante mudanças de direção. Os ciclos de TVOL/AY, TVOL/AVOL e AVOL/AY são apresentados na figura 18.

Figura 18. Ciclos TVOL/AY, TVOL/AVOL e AVOL/AY.



Fonte: Elaboração pelo autor (2025).

3.2 Definição da escala subjetiva

No trabalho realizado por Gil Gómez *et al.* (2015), demonstrou-se que a definição original da escala subjetiva proposta pela SAE, que varia entre 1 e 10 pontos não é completamente adequada para a avaliação de veículos de produção. Isso ocorre porque, na prática, as avaliações realizadas por especialistas tendem a concentrar-se em poucos pontos intermediários da escala, especialmente 6, 6,5, 7, 7,5 e 8. O que reduz o poder discriminatório da escala e limita a possibilidade de identificar correlações robustas entre métricas objetivas e avaliações subjetivas. Em Gil Gómez *et al.* (2015) é indicado que uma escala visual, na qual os avaliadores selecionam uma posição ao longo de uma linha contínua, apresenta maior resolução comparada à inserção de um valor numérico.

A escala subjetiva utilizada neste trabalho, conforme apresentado no quadro 2, é dividida em 3 macro parâmetros que são representados por 10 subdivisões. Cada subdivisão conta com uma escala com 17 posições.

Quadro 2. Parâmetros subjetivos e ficha de avaliação.

Nº	Macro Parâmetro	Parâmetro	Avaliação															
S1	Resposta Direcional	Prontidão da resposta																
S2	Resposta Direcional	Facilidade em manter a trajetória em curva																
S3	Resposta Direcional	Atraso da resposta do eixo posterior																
S4	Resposta Direcional	Progressão do ângulo de direção em curvas																
S5	Rolagem	Comportamento de rolagem																
S6	Rolagem	Velocidade de rolagem																
S7	Sensação de Direção	Sensação ao centro																
S8	Sensação de Direção	Esforço de direção / progressão																
S9	Sensação de Direção	Atraso da resposta direcional																

Fonte: Elaboração pelo autor (2025).

As nove métricas subjetivas foram organizadas em três macro parâmetros conceitualmente independentes, que refletem dimensões complementares da experiência de condução. O primeiro macro parâmetro, denominado Resposta Direcional, compreende quatro aspectos: prontidão da resposta (S1), que avalia a percepção da rapidez com que o veículo responde ao comando de direção; facilidade em manter a trajetória em curva (S2), relacionada ao esforço cognitivo necessário para sustentar a trajetória desejada; atraso da resposta do eixo posterior (S3), que expressa a defasagem percebida entre o comando do volante e a rotação do veículo; e progressão do ângulo de direção (S4), que avalia a linearidade da resposta do veículo ao aumento do ângulo de esterçamento.

O segundo macro parâmetro, Rolagem, é composto por dois indicadores. O primeiro, S5, representa a magnitude e a sensação da inclinação lateral da carroceria durante curvas, enquanto o segundo, S6, expressa a velocidade de rolagem. Esses aspectos são essenciais para a percepção de controle e estabilidade do veículo em situações dinâmicas.

Por fim, o macro parâmetro Sensação de Direção abrange três métricas: a definição ao centro (S7), que avalia a clareza da posição neutra e a resposta dos veículos para entradas pequenas de ângulo de volante; o esforço de direção e sua progressão (S8), que consideram tanto o nível absoluto de torque quanto sua variação ao longo de uma curva; e o atraso da resposta direcional (S9), que quantifica a latência global percebida entre o comando e a alteração efetiva da trajetória.

3.3 Pré-processamento e tratamento dos dados

A presença de valores extremos ou inconsistentes pode comprometer significativamente a qualidade dos resultados obtidos em modelos estatísticos e técnicas de aprendizado de máquina, prejudicando a interpretação e aumentando a variabilidade das estimativas. Assim, antes de aplicar métodos para agrupamento ou predição, é necessário realizar procedimentos específicos para a identificação e tratamento desses dados. Nessa etapa, são apresentados métodos para avaliação da multicolinearidade entre variáveis, seleção adequada das métricas mais relevantes e normalização das variáveis.

3.3.1 Remoção de multicolinearidade

Para reduzir redundâncias e evitar que variáveis altamente correlacionadas comprometam a eficiência dos modelos, será realizada uma análise da matriz de correlação de Pearson. Variáveis com coeficientes de correlação superiores a $|0,75|$ serão removidas. Nos casos em que mais de uma variável apresentar correlação, será mantida aquela que apresentar o maior número de correlações dentro do grupo de variáveis correlacionadas.

3.3.2 Normalização dos dados

Para que todas as variáveis contribuam de maneira equitativa nas análises subsequentes – como na clusterização e nas previsões – os dados numéricos serão normalizados utilizando a técnica *Min-Max*.

3.4 Agrupamento de veículos similares

Etapa prévia à aplicação do algoritmo *K-Means*, a redução da dimensionalidade no presente estudo fundamenta-se na Análise de Componentes Principais.

O algoritmo *K-Means* utilizado para realizar o agrupamento dos dados, permitindo identificar grupos homogêneos, de forma que as observações dentro de um mesmo grupo sejam mais similares entre si do que com as de outros grupos.

3.5 Previsão do desempenho subjetivo

Para estabelecer relações preditivas entre as métricas objetivas e as avaliações subjetivas, foram abordados modelos clássicos de aprendizado de máquina, sendo estes: Regressão Linear, Regressão Ridge, KNN, *RandomForest*. Estes modelos foram selecionados por sua capacidade de capturar as relações entre dados de diferentes maneiras, com o intuito de servir de base comparativa para as redes neurais artificiais desenvolvidas.

Os modelos foram implementados em duas abordagens complementares. Análise Multivariada com o objetivo de prever simultaneamente todas as métricas subjetivas (S1 a S9) a partir das métricas objetivas, capturando potenciais relações entre as diferentes avaliações subjetivas.

Análise univariada com objetivo de prever cada métrica subjetiva individualmente, permitindo uma avaliação mais detalhada da influência das métricas objetivas para cada aspecto específico da avaliação subjetiva.

3.6 Análise de importância

A metodologia empregada para a análise de importância das features no presente estudo fundamenta-se na técnica conhecida como Análise de Importância por Permutação. Esta abordagem consiste em avaliar a degradação do desempenho do modelo quando os valores de uma determinada *feature* são aleatoriamente permutados, rompendo assim sua relação com a variável-alvo, enquanto mantém-se a estrutura marginal da distribuição e as relações entre as demais variáveis.

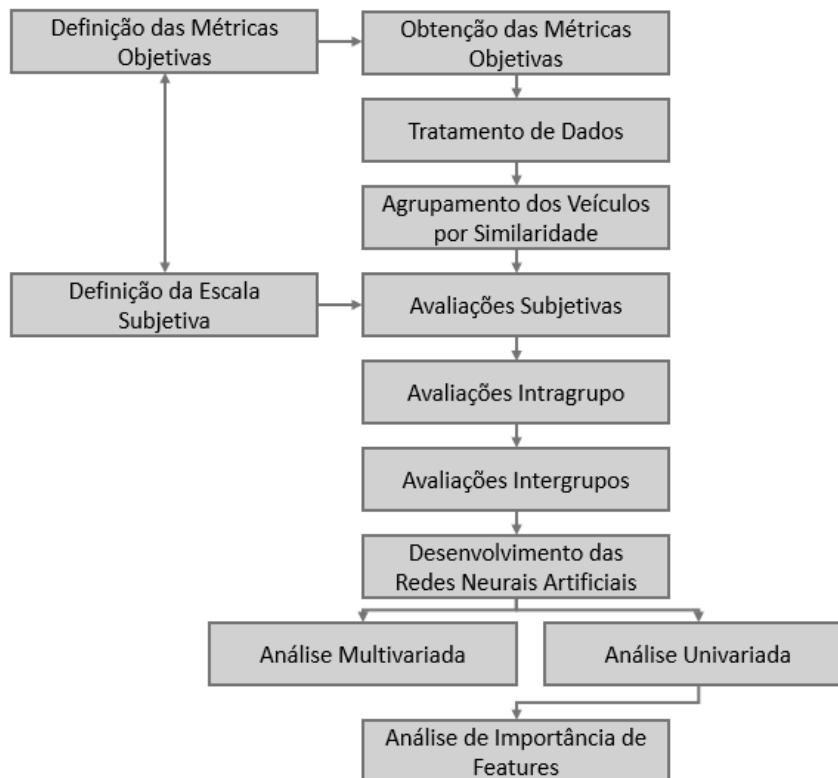
3.7 Implementação computacional

A implementação dos modelos de aprendizado de máquina foi realizada através de um conjunto de bibliotecas em linguagem Python. As principais bibliotecas utilizadas foram: *Scikit-learn* para os algoritmos clássicos de machine learning, pré-processamento de dados e validação cruzada, *TensorFlow* para desenvolvimento e treinamento das arquiteturas de redes neurais, *NumPy* e *Pandas* para manipulação e análise de dados, e *Matplotlib* e *Seaborn* para visualização de resultados.

4. RESULTADOS

Nesta seção, são apresentados os resultados obtidos a partir da aplicação dos métodos descritos anteriormente, o fluxo das etapas ocorre de acordo com a figura 19. Os resultados são organizados de forma a refletir a sequência das etapas metodológicas, iniciando com a obtenção e tratamento dos dados objetivos, análise dos agrupamentos gerados pelo algoritmo de aprendizado não supervisionado e obtenção das notas subjetivas. Na sequência é abordado o desenvolvimento e desempenho dos modelos de aprendizado supervisionado na predição das notas subjetivas. É realizada a análise de importância para interpretação dos resultados e verificação da correspondência entre os dados objetivos e as percepções subjetivas.

Figura 19. Fluxograma da metodologia.



Fonte: Elaboração pelo autor (2025).

4.1 Obtenção dos dados

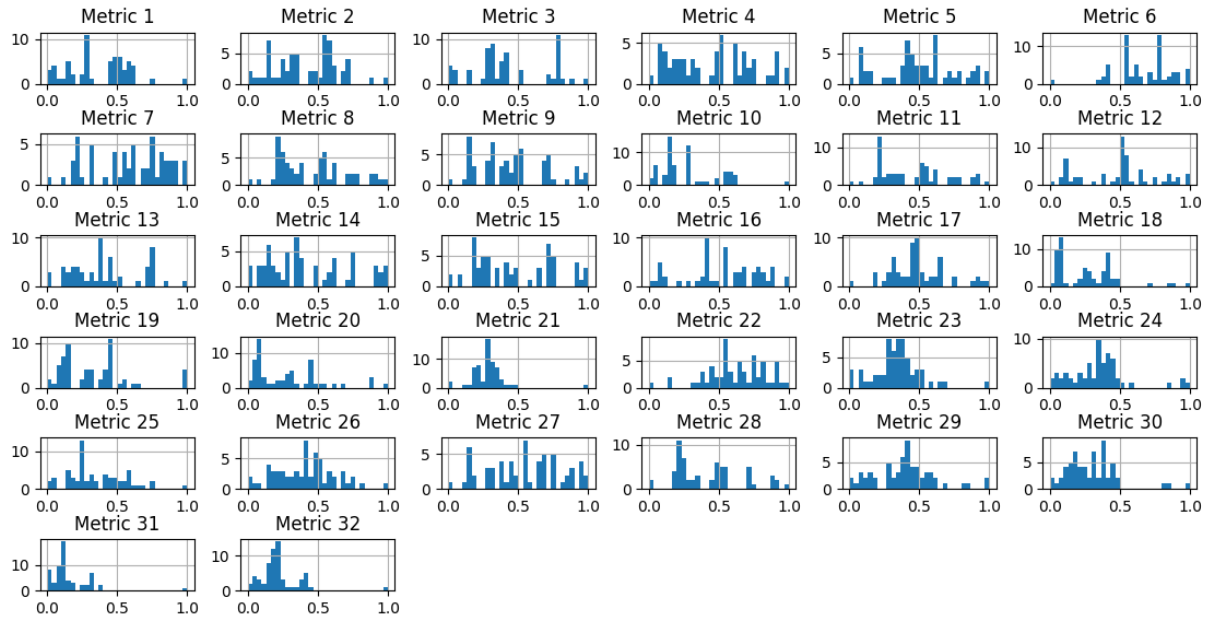
A coleta dos dados foi realizada através de simulações de malha aberta dos testes apresentados na seção 2.7, a partir de modelos paramétricos, construídos no software VI-CarRealTime, com base em caracterizações de componentes e do sistema de suspensão de veículos.

O banco de dados utilizado neste estudo inclui 32 métricas objetivas, obtidas para 57 veículos. Esses veículos provêm de 4 fabricantes diferentes e abrangem as classes B (compactos), C (médios), CPU (veículos utilitários médios).

4.2 Tratamento de dados

Os histogramas das métricas normalizadas (figura 20) permitem visualizar a forma de cada distribuição. Observa-se que determinadas variáveis exibem caudas alongadas e picos deslocados, evidenciando assimetria, um indicativo visual de que os dados podem conter valores extremos. Em alguns casos, como na Métrica 10 e na Métrica 21, os histogramas demonstram um desvio acentuado em relação à simetria, sugerindo a necessidade de um tratamento posterior para remoção dos outliers.

Figura 20. Histograma das Métricas Normalizadas



Fonte: Elaboração pelo autor (2025).

4.2.1 Remoção de multicolinearidade

A figura 21 ilustra a matriz de correlação antes da remoção das métricas colineares, evidenciando coeficientes superiores a $|0,75|$ em diversas células. Esse alto grau de correlação confirma a presença de multicolinearidade no conjunto de dados.

No contexto de torque de direção, o Ganho de TVOL/AVOL no trecho Linear (Métrica 20) substituiu tanto o TVOL Máximo (Métrica 18) quanto a Amplitude de TVOL para AY igual a 0,3 g (Métrica 19), consolidando em um único indicador as principais características desse parâmetro. Além disso, a Amplitude do TVOL para AY igual a 0 g (Métrica 23) absorveu as medições relativas à Amplitude de TVOL para AVOL = 0 (Métrica 29) e à de Amplitude do TVOL para AY igual a 0 g (Métrica 24). Por fim, a Amplitude de TVOL para AVOL igual a 0 (Métrica 30) foi mantida no lugar da Amplitude de TVOL na mudança de direção (Métrica 32), enquanto o Ganho Dinâmico de PISP/AVOL a 1 Hz (Métrica 9), ainda que tenha substituído o Ganho de AY/AVOL (Métrica 27), também acabou incorporado ao Gradiente de subesterço @AVOL (Métrica 1) devido à alta correlação entre ambos. A figura 22 apresenta a matriz de correlação após a exclusão das métricas redundantes.

Figura 22. Matriz De Correlação Final


Metric 1	1.0	0.34	-0.65	0.48	0.24	-0.43	-0.46	0.52	-0.14	0.31	-0.46	0.06	-0.29
Metric 3	0.34	1.0	-0.71	0.42	-0.17	-0.61	-0.31	-0.09	-0.24	0.32	-0.16	-0.05	-0.42
Metric 4	-0.65	-0.71	1.0	-0.52	-0.26	0.32	0.47	-0.47	0.34	-0.31	0.5	-0.07	0.46
Metric 10	0.48	0.42	-0.52	1.0	0.5	0.09	-0.19	0.38	-0.18	0.2	0.03	0.09	0.09
Metric 15	0.24	-0.17	-0.26	0.5	1.0	0.69	0.02	0.5	-0.2	0.09	-0.12	0.26	0.07
Metric 16	-0.43	-0.61	0.32	0.09	0.69	1.0	0.36	0.19	0.02	-0.2	0.24	0.15	0.39
Metric 17	-0.46	-0.31	0.47	-0.19	0.02	0.36	1.0	-0.19	0.26	-0.22	0.46	-0.05	0.37
Metric 20	0.52	-0.09	-0.47	0.38	0.5	0.19	-0.19	1.0	-0.04	0.43	-0.36	0.47	-0.25
Metric 21	-0.14	-0.24	0.34	-0.18	-0.2	0.02	0.26	-0.04	1.0	0.12	0.15	-0.1	0.28
Metric 22	0.31	0.32	-0.31	0.2	0.09	-0.2	-0.22	0.43	0.12	1.0	-0.27	0.69	-0.62
Metric 24	-0.46	-0.16	0.5	0.03	-0.12	0.24	0.46	-0.36	0.15	-0.27	1.0	-0.15	0.7
Metric 25	0.06	-0.05	-0.07	0.09	0.26	0.15	-0.05	0.47	-0.1	0.69	-0.15	1.0	-0.56
Metric 30	-0.29	-0.42	0.46	0.09	0.07	0.39	0.37	-0.25	0.28	-0.62	0.7	-0.56	1.0
	Metric 1	Metric 3	Metric 4	Metric 10	Metric 15	Metric 16	Metric 17	Metric 20	Metric 21	Metric 22	Metric 24	Metric 25	Metric 30

Fonte: Elaboração pelo autor (2025).

4.2.2 Normalização dos dados


A figura 23 ilustra a distribuição das métricas antes da normalização, evidenciando as discrepâncias de escala e as diferentes unidades de medida. Tais variações poderiam comprometer a qualidade das análises, uma vez que variáveis com valores mais elevados tenderiam a dominar o processo analítico. A figura 24, por sua vez, ilustra a distribuição das métricas após a normalização.

Figura 23. Distribuição Inicial Das Métricas



Fonte: Elaboração pelo autor (2025).

Figura 24. Distribuição Final Das Métricas.




Fonte: Elaboração pelo autor (2025).

4.2.3 Análise de componentes principais

A análise de componentes principais revelou que os quatro primeiros componentes principais explicaram cerca de 81% da variância total dos dados, com as maiores contribuições sendo observadas para os dois primeiros componentes, conforme apresentado na figura 25.


Figura 25. Variância Explicada Por Número De Componentes



Fonte: Elaboração pelo autor (2025).

A projeção das amostras nos dois primeiros componentes principais (figura 26) mostrou grupos distintos, sugerindo uma separação entre as amostras. A visualização desses componentes, como ilustrado no gráfico de dispersão, permitiu uma interpretação visual dos dados, destacando agrupamentos que indicam similaridades entre as amostras com base nas métricas avaliadas.


Figura 26. Projeção PCA1 x PCA2



Fonte: Elaboração pelo autor (2025).

A análise das cargas dos componentes principais (PCA), ilustrada pela figura 27, realizada sobre as métricas revela a contribuição distinta de cada variável nos componentes extraídos, destacando a variabilidade subjacente do conjunto de dados.

Figura 27. Matriz de Carga dos Componentes Principais




Fonte: Elaboração pelo autor (2025).

No primeiro componente principal (PC1), a Métrica 4 apresentou uma carga positiva expressiva, enquanto as Métricas 1 e 3 exibiram cargas negativas, os parâmetros de maior efeito nessa componente principal fazem parte do macro parâmetro pré-definido de reposta direcional. Adicionalmente, no segundo componente principal (PC2), as Métricas 15, 16 e 20 destacaram-se com alta carga positiva. Esse conjunto sugere que tais indicadores estão intimamente associados a variações específicas que auxiliam na separação das amostras, a presença de cargas altas nas métricas relacionadas a dinâmica de rolagem, indica que PC2 é indicativa desse macro parâmetro. No terceiro componente principal (PC3), observou-se uma interação diferenciada, com as Métricas 22, 25 e 26 apresentando cargas positivas significativas, enquanto a Métrica 30 contribuiu negativamente. O grupo de métricas de maior influência sobre PC3 indicam que esta componente está relacionada à sensação de direção. A quarta componente (PC4) possui cargas altas de métricas representativas dos 3 macro parâmetros, com contribuições notáveis das métricas 17, 30 e 10.

4.2.4 K-Means

A figura 28 apresenta a variação da soma dos erros quadráticos (SSE) pelo número de agrupamentos. A análise do gráfico revela que o valor de $k=5$ há uma desaceleração significativa na curva, indicando que esse é o número ideal de agrupamentos a ser utilizado.


Figura 28. SSE Pelo Número De Agrupamentos



Fonte: Elaboração pelo autor (2025).

A figura 29 mostra a visualização bidimensional dos agrupamentos. Cada ponto representa um veículo e é colorido de acordo com o cluster ao qual pertence.


Figura 29. Visualização 2D dos Agrupamentos.



Fonte: Elaboração pelo autor (2025).

A figura 30 apresenta a visualização dos agrupamentos com a inclusão das informações de classes e fabricantes, pode-se perceber que certos fabricantes ou classes tendem a se agrupar, o que sugere que as características desses veículos são semelhantes.

Figura 30. Verificação Das Separações Por Classe E Fabricante



Fonte: Elaboração pelo autor (2025).

4.3 Obtenção das métricas subjetivas

Foram coletadas notas subjetivas dos veículos simulados por meio de um simulador de direção (VI-grade DiM-150), no qual um avaliador experiente registrou suas impressões, de forma comparativa, seguindo a escala de desempenho subjetiva definida na seção 3.2.

Para a avaliação subjetiva dos veículos simulados, adotou-se uma abordagem baseada nos resultados obtidos pelo algoritmo *K-Means* de aprendizado de máquina não supervisionado. Inicialmente, o algoritmo realizou a separação dos 57 veículos simulados em diferentes agrupamentos, considerando a similaridade de suas métricas objetivas. A partir dessa classificação, definiu-se um veículo de referência, mais central ao agrupamento como representativo do comportamento típico esperado, para servir como base comparativa durante as avaliações subjetivas realizadas no simulador. Após a seleção da amostra central, outras amostras foram selecionadas aleatoriamente dentro do agrupamento.

Do total de 57 veículos simulados, foram selecionados 25 modelos para serem avaliados no simulador de direção. O método de seleção garantiu que nuances entre os resultados pudessem ser percebidos entre veículos que se comportam similarmente, conforme relatado pelo avaliador. Após a avaliação intragrupo, foi realizada a avaliação intergrupos, com a finalidade de aumentar a quantidade de amostras úteis para o desenvolvimento da rede.

A tabela 1 apresenta a distribuição das notas na escala subjetiva de acordo com a escala proposta na seção 3.2, a apresentação dos valores considera os limites inferior e superior da escala como 5 e 9, respectivamente. Os histogramas gerais dos parâmetros subjetivos e os *boxplots* por agrupamento são apresentados nos Apêndices A e B, respectivamente. A partir da análise dos resultados, observa-se que alguns grupos apresentaram maiores variações de certos parâmetros, enquanto alguns parâmetros não apresentam variação alguma quando avaliados dentro de um certo agrupamento (*Cluster*). Essa distribuição limita a caracterização de fenômenos quando avaliados dentro de um certo grupo e sugere a necessidade de aumento da quantidade de amostras para avaliação intragrupo.

Tabela 1. Estatísticas descritivas dos parâmetros subjetivos.

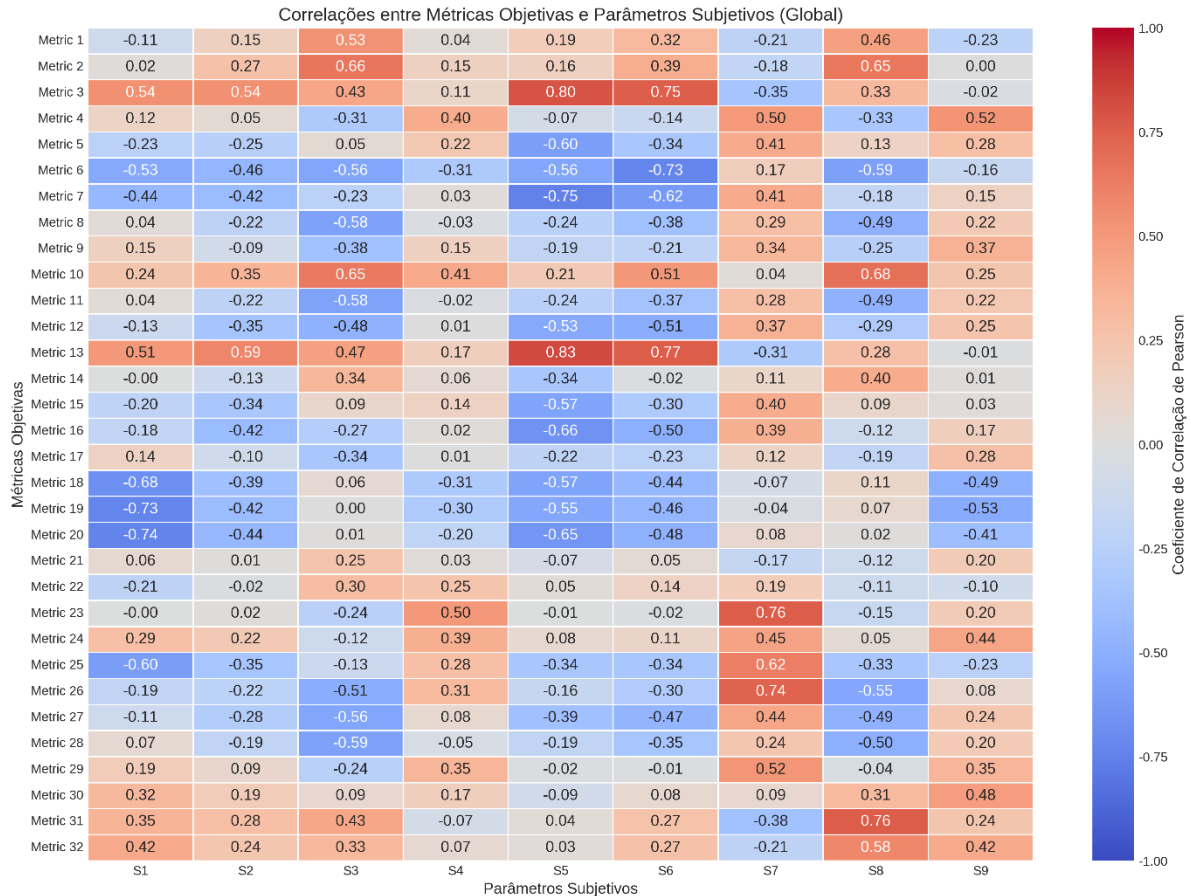
	S1	S2	S3	S4	S5	S6	S7	S8	S9
Contagem	25	25	25	25	25	25	25	25	25
Média	7,57	7,56	7,57	7,05	7,25	7,38	7,53	6,3	8,04
Desvio Padrão	0,42	0,44	0,34	0,54	0,56	0,59	0,66	0,56	0,34
Mín,	6,5	6,75	6,75	6,25	6	6	5,75	5,5	7,25
25%	7,5	7,25	7,25	6,5	6,75	7	7,5	6	7,75
50%	7,75	7,75	7,75	7	7,25	7,5	7,5	6	8
75%	7,75	7,75	7,75	7,5	7,75	7,75	8	6,75	8,25
Máx,	8	8,25	8	8	8,25	8,5	8,5	7,25	8,5

Fonte: Elaboração pelo autor (2025).

4.4 Análise de correlações

A figura 31 apresenta os resultados da análise de correlações aplicada sobre o conjunto completo de dados. Os resultados revelam diversas correlações significativas entre métricas objetivas e parâmetros subjetivos, algumas correlações parecem existir devido à quantidade limitada de dados, porém outras são consistentes com os macro parâmetros definidos.

Figura 31. Matriz de correlação global.



Fonte: Elaboração pelo autor (2025).

Entre as correlações mais destacadas, encontra-se a métrica 31 (Amplitude de TVOL na mudança de direção - 60 km/h) com S8 (Esforço de direção / progressão), apresentando correlação de 0.76. A métrica 23 (Amplitude do TVOL @ AY = 0g - 60 km/h) demonstrou forte correlação de 0.76 com S7 (Sensação ao centro). Adicionalmente, a métrica 3 (Gradiente do ângulo de deriva lateral) correlacionou-se significativamente com S6 (Velocidade de rolagem) em 0.75. Também se observou correlação importante entre a métrica 26 (Ganho de TVOL/AVOL - 120 km/h) e S7 (Sensação ao centro) de 0.74, enquanto a métrica 20 (Ganho de TVOL/AVOL no trecho Linear) apresentou correlação negativa de -0.74 com S1 (Prontidão da resposta).

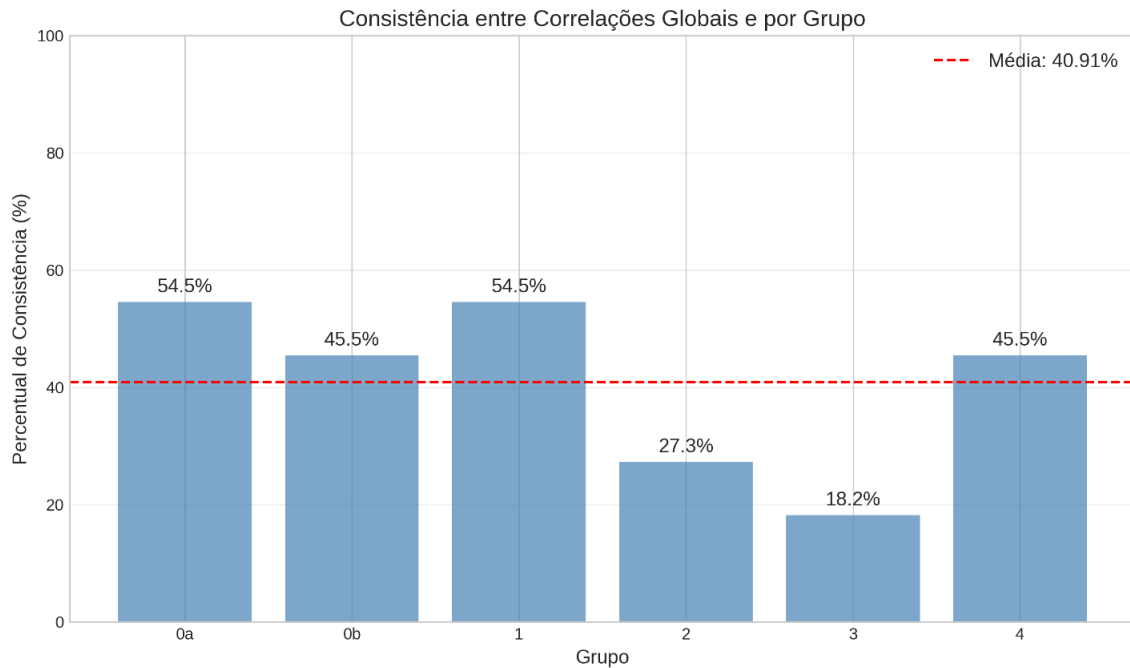
Ao agrupar as correlações por macro parâmetros, observaram-se padrões consistentes na relação entre categorias de métricas objetivas e subjetivas. A categoria Resposta Direcional Objetiva versus Rolagem Subjetiva apresentou média de correlação absoluta de 0.77 considerando seis pares de variáveis. O grupo Esforço de Direção Objetivo versus Esforço de Direção Subjetivo demonstrou média de correlação absoluta de 0.75 com três pares analisados. Por fim, a relação entre Esforço de Direção Objetivo e Resposta Direcional Subjetiva evidenciou média de correlação absoluta de 0.74 em dois pares de variáveis.

Estes resultados indicam que as métricas de Resposta Direcional apresentam forte correlação com parâmetros subjetivos de Rolagem, sugerindo uma relação significativa entre a resposta direcional do veículo e a percepção de rolagem pelos avaliadores. Similarmente, existe uma forte correlação entre métricas e avaliações subjetivas dentro da categoria de Esforço de Direção, indicando consistência entre medidas objetivas e percepção subjetiva neste aspecto.

O Apêndice C contém as matrizes de correlação por agrupamento.

A figura 32 indica a consistência das correlações quando analisadas no conjunto de dados completo em comparação com cada agrupamento.

Figura 32. Consistência entre correlações globais e por grupo



Fonte: Elaboração pelo autor (2025).

A análise de consistência entre as correlações globais e por grupo revelou um percentual médio de consistência de 40.91. Esta variabilidade na consistência sugere que a agregação de dados em nível global pode mascarar padrões específicos de correlação presentes em subgrupos da amostra.

Na análise foram identificadas 9 ocorrências de mudanças de sinal nas correlações entre a análise global e por grupos. Estas mudanças indicam que a direção da relação entre uma métrica objetiva e um parâmetro subjetivo se inverte em determinados grupos.

Apesar da variabilidade, alguns padrões de correlação por macro parâmetros se mantêm relativamente consistentes, como a forte correlação entre Resposta Direcional e Rolagem, e entre métricas e avaliações subjetivas dentro da categoria de Esforço de Direção.

4.5 Aprendizado supervisionado

Esta seção apresenta os resultados obtidos, com ênfase nas redes neurais artificiais e sua comparação com modelos clássicos de aprendizado de máquina.

4.5.1 Modelos clássicos de aprendizado de máquina

Modelos clássicos de aprendizado de máquina foram usados como base comparativa para as redes neurais. A tabela 2 apresenta um resumo do desempenho desses modelos.

Tabela 2. Desempenho dos Modelos Clássicos

Modelo	REQM	R ²	Tempo (s)
KNN	0,5062	1	2,42
RandomForest	0,5674	0,814	15,3
Ridge	0,5964	0,6981	1,06
Linear	0,7312	0,8451	0,76

Fonte: Elaboração pelo autor (2025).

Os resultados mostram que os modelos não-lineares (KNN, *RandomForest*) consistentemente superaram os modelos lineares em termos de REQM e R². O algoritmo KNN apresentou o menor REQM e R² = 1.0000, sugerindo um ajuste perfeito aos dados de treinamento, o que é um indicativo de sobreajuste considerando o tamanho limitado do conjunto de dados.

4.5.2 Redes neurais artificiais

Foram desenvolvidas e avaliadas duas arquiteturas principais de redes neurais, denominadas de Rede Neural Artificial 1 (RNA_1) e Rede Neural Artificial 2 (RNA_2). O quadro 3 apresenta os hiperparâmetros considerados para o treinamento de cada uma das arquiteturas.


Quadro 3. Hiperparâmetros das redes neurais artificiais

	RNA_1	RNA_2
Camadas ocultas [Neurônios]	[64, 32]	[128, 64, 32]
Ativação das camadas ocultas	ReLU	ReLU
Ativação da camada de saída	Linear	Linear
Otimizador	Adam	Adam
<i>dropout</i>	0,2	0,2
<i>batch_norm</i>	Verdadeiro	Verdadeiro
Épocas	200	300
<i>batch_size</i>	8	8
Paciência	Não	20
Regularizador L1	0,001	0,001
Regularizador L2	0,1	0,1
Taxa de aprendizado	0,001	0,001

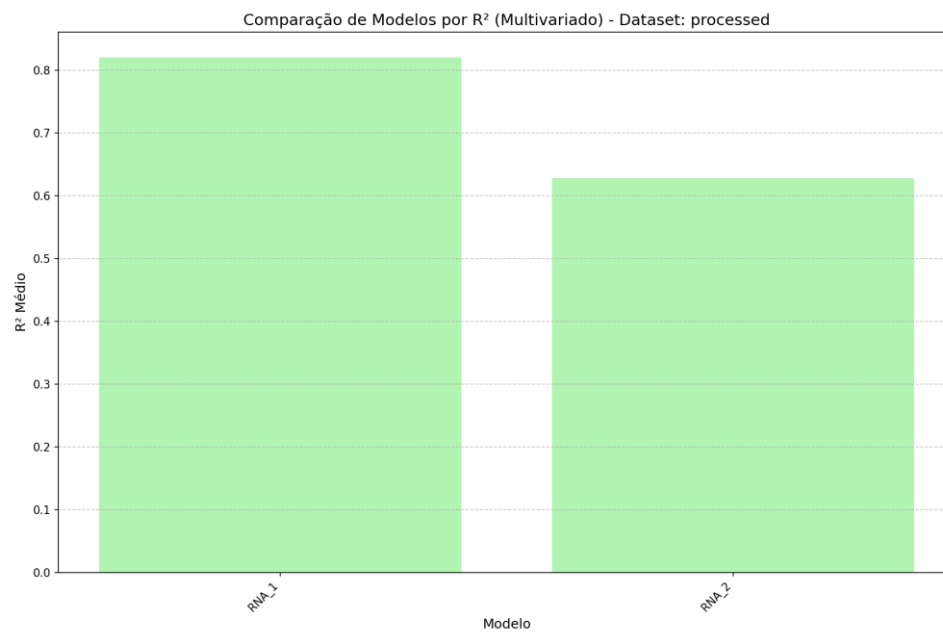
Fonte: Elaboração pelo autor (2025).

Os resultados comparativos de REQM e R^2 das redes neurais artificiais na análise multivariada são apresentados nas figuras 33 e 34, respectivamente.

Figura 33. Comparação do Erro Quadrático Médio de validação de RNA_1 e RNA_2.




Fonte: Elaboração pelo autor (2025).

Figura 34. Comparação de R^2 de validação de RNA_1 e RNA_2.

Fonte: Elaboração pelo autor (2025).


As figuras 35 e 36 apresentam a curva de aprendizado das redes neurais.

Figura 35. Curva de aprendizado RNA_1.



Fonte: Elaboração pelo autor (2025).

Figura 36. Curva de aprendizado RNA_2.



Fonte: Elaboração pelo autor (2025).

A tabela 3 apresenta a síntese do resultado comparativo entre as redes neurais artificiais.

Tabela 3. Comparação de Desempenho entre Redes Neurais.

	REQM	EQM	R ²	Perda de Validação	Épocas	Tempo de execução (s)
RNA_1	0,21	0,15	0,82	0,53	200	13
RNA_2	0,30	0,23	0,63	1,20	300	53

Fonte: Elaboração pelo autor (2025).

A análise isolada da Raiz do Erro Quadrático Médio e R² sugerem um desempenho melhor de RNA_1 sobre RNA_2. Porém, observa-se para RNA_1 forte indício de sobreajuste, visto que a curva de perda de validação em diversas épocas apresenta resultado inferior à curva de validação de treinamento. Para RNA_2 a curva de aprendizado indica bom comportamento do modelo em generalizar resultados.

Com base nos resultados apresentados, para as análises subsequentes, este estudo considerou a arquitetura RNA_2.

4.5.3 Comparativo dos resultados multivariados

A tabela 4 apresenta uma comparação do desempenho de RNA_2 com os modelos clássicos na análise multivariada.

Tabela 4. Comparação de Desempenho entre RNA_2 e Modelos Clássicos.

Modelo	REQM	R ²	Tempo de execução(s)
RNA_2	0,3009	0,6282	53,41
KNN	0,5062	1	2,42
RandomForest	0,5674	0,814	15,3
Ridge	0,5964	0,6981	1,06
Linear	0,7312	0,8451	0,76

Fonte: Elaboração pelo autor (2025).

As redes neurais demonstraram desempenho significativamente superior aos modelos clássicos em termos de REQM, com a Rede Neural Avançada alcançando uma redução de aproximadamente 40% no erro quadrático médio em comparação com o melhor modelo clássico. Além disso, RNA_2 manteve valores de R² mais realistas, indicando melhor equilíbrio entre ajuste aos dados de treinamento e capacidade de generalização.

4.5.4 Resultados univariados

A tabela 5 apresenta os resultados do melhor modelo para predição de cada parâmetro subjetivo na análise univariada. As redes neurais superaram consistentemente os modelos clássicos para todas as métricas subjetivas. O Apêndice D contém as tabelas com os resultados dos comparativos dos métodos para cada parâmetro subjetivo.

Tabela 5. Melhor modelo por parâmetro subjetivo.

Target	Melhor Modelo	REQM	R ²
S1	RNA_2_S1	0,1518	0,8625
S2	RNA_2_S2	0,2353	0,703
S3	RNA_2_S3	0,2329	0,5183
S4	RNA_2_S4	0,2612	0,7606
S5	RNA_2_S5	0,2739	0,754
S6	RNA_2_S6	0,2431	0,8239
S7	RNA_2_S7	0,2811	0,8103
S8	RNA_2_S8	0,2083	0,8577
S9	RNA_2_S9	0,1342	0,8339

Fonte: Elaboração pelo autor (2025).

Os resultados mostram que de maneira geral os valores de REQM se mantiveram entre 20% e 30%, com exceção dos parâmetros S1 e S9, com 15% e 13%, respectivamente.

4.5.5 Análise de importância de *features*

A seguir são apresentados os resultados da análise de importância de *Features* por permutação para RNA_2. Para cada parâmetro subjetivo, são apresentadas as dez métricas objetivas com maior impacto absoluto, permitindo a identificação tanto da magnitude quanto da direção da influência de cada métrica.

4.5.5.1 Prontidão da resposta

A tabela 6 apresenta as dez métricas de maior impacto absoluto para o parâmetro “Prontidão Da Resposta” (S1), em ordem decrescente.

Tabela 6. Importância média para parâmetro S1.

Métrica	Descrição	Importância Média
Métrica 19	Amplitude do torque para AY = 0,3 g	-0,074
Métrica 24	Amplitude do TVOL @ AY = 0g - 120 km/h	-0,0623
Métrica 20	Ganho de TVOL/AVOL no trecho Linear	-0,0601
Métrica 18	TVOL Máximo	-0,0583
Métrica 22	Tempo de reposta de AVOL/TVOL @ 1 Hz	0,0581
Métrica 25	Ganho de TVOL/AVOL - 60 km/h	-0,0407
Métrica 29	Amplitude do torque para AVOL=0 - 60 km/h	0,0371
Métrica 6	Tempo de reposta de Taxa de Guinada/AY @ 1 Hz	-0,0366
Métrica 2	Gradiente de subesterço na roda	0,035
Métrica 32	Amplitude de TVOL na mudança de direção - 120 km/h	-0,0341

Fonte: Elaboração pelo autor (2025).

Os resultados sugerem que a percepção de prontidão está fortemente associada às características de torque no volante, ao gradiente de subesterço na roda e aos tempos de resposta do sistema.

4.5.5.2 Facilidade em manter a trajetória em curva

A tabela 7 apresenta as dez métricas mais influentes na resposta da rede neural artificial para o parâmetro “Facilidade Em Manter A Trajetória Em Curva” (S2).

Tabela 7. Importância média para parâmetro S2.

Métrica	Descrição	Importância Média
Métrica 4	Limite linear de AY	0,0489
Métrica 2	Gradiente de subesterço na roda	0,0197
Métrica 10	Linearidade de Taxa de Guinada/AVOL	0,0176
Métrica 21	Progressão de TVOL Durante a Curva	0,0175
Métrica 20	Ganho de TVOL/AVOL no trecho Linear	-0,0139
Métrica 15	Gradiente de Rolagem/AY @ 1 Hz	-0,0126
Métrica 7	Tempo de reposta de AY/AVOL @ 1 Hz	-0,0124
Métrica 9	Ganho Dinâmico de Taxa de Guinada/AVOL @ 1 Hz	0,0123
Métrica 25	Ganho de TVOL/AVOL - 60 km/h	0,0123
Métrica 24	Amplitude do TVOL @ AY = 0g - 120 km/h	-0,0118

Fonte: Elaboração pelo autor (2025).

A predominância de métricas relacionadas ao comportamento linear e aos gradientes de subesterço corrobora a importância dessas métricas sobre a previsibilidade do comportamento veicular em curvas. Observa-se também a presença de parâmetros relacionados à resposta de torque no volante.

4.5.5.3 Atraso da resposta do eixo posterior

A percepção do “Atraso Da Resposta Do Eixo Posterior” (S3) mostrou-se influenciada por métricas que capturam a dinâmica de resposta do veículo e a coordenação entre os eixos. A tabela 8 apresenta as dez métricas mais influentes na resposta da rede neural artificial.

Tabela 8. Importância média para parâmetro S3.

Métrica	Descrição	Importância Média
Métrica 20	Ganho de TVOL/AVOL no trecho Linear	0,05
Métrica 3	Gradiente do ângulo de deriva posterior	0,0415
Métrica 6	Tempo de reposta de Taxa de Guinada/AY @ 1 Hz	0,035
Métrica 31	Amplitude de TVOL na mudança de direção - 60 km/h	-0,031
Métrica 19	Amplitude do torque para AY = 0,3 g	0,0268
Métrica 13	Ganho Dinâmico de Taxa de Guinada/AY @ 1 Hz	0,0217
Métrica 25	Ganho de TVOL/AVOL - 60 km/h	0,0202
Métrica 10	Linearidade de Taxa de Guinada/AVOL	0,0169
Métrica 18	TVOL Máximo	0,0163
Métrica 27	Ganho de AY/AVOL - 60 km/h	-0,0147

Fonte: Elaboração pelo autor (2025).

A presença significativa de métricas relacionadas aos tempos de resposta e aos gradientes de deriva posterior evidencia que o avaliador consegue perceber sutilezas na coordenação entre os eixos dianteiro e traseiro. Das métricas com maior importância média, destaca-se o gradiente do ângulo de deriva posterior e o tempo de resposta de taxa de guinada por aceleração lateral.

4.5.5.4 Progressão do ângulo de direção em curvas

A análise da “Progressão Do Ângulo De Direção Em Curvas” (S4) destacou a importância das características lineares e da resposta em frequência do sistema de direção. A tabela 9 apresenta as dez métricas mais influentes na resposta da rede neural artificial.

Tabela 9. Importância média para parâmetro S4.

Métrica	Descrição	Importância Média
Métrica 10	Linearidade de Taxa de Guinada/AVOL	0,0655
Métrica 16	Gradiente de Taxa de Rolagem/AVOL @ 1 Hz	0,0625
Métrica 5	Tempo de resposta de Taxa de Guinada/AVOL @ 1 Hz	-0,0542
Métrica 24	Amplitude do TVOL @ AY = 0g - 120 km/h	0,0472
Métrica 26	Ganho de TVOL/AVOL - 120 km/h	-0,0452
Métrica 7	Tempo de reposta de AY/AVOL @ 1 Hz	-0,0439
Métrica 25	Ganho de TVOL/AVOL - 60 km/h	-0,0419
Métrica 2	Gradiente de subesterço na roda	0,0398
Métrica 8	Ganho Estático de Taxa de Guinada/AVOL @ 0 Hz	0,0372
Métrica 23	Amplitude do TVOL @ AY = 0g - 60 km/h	-0,0335

Fonte: Elaboração pelo autor (2025).

A predominância de métricas relacionadas à linearidade e aos tempos de resposta sugere que a percepção de progressão adequada depende fundamentalmente da previsibilidade e consistência da resposta do sistema de direção, observa-se também influência alta do gradiente de taxa de rolagem por ângulo de volante na determinação do parâmetro S4.

4.5.5.5 Comportamento de rolagem

Para o “Comportamento De Rolagem” (S5), as métricas mais influentes refletem diretamente os aspectos relacionados ao movimento de rolagem do veículo. A tabela 10 apresenta as dez métricas mais influentes na resposta da rede neural artificial.

Tabela 10. Importância média para parâmetro S5.

Métrica	Descrição	Importância Média
Métrica 15	Gradiente de Rolagem/ $AY @ 1 \text{ Hz}$	-0,0387
Métrica 10	Linearidade de Taxa de Guinada/ $AVOL$	0,0318
Métrica 9	Ganho Dinâmico de Taxa de Guinada/ $AVOL @ 1 \text{ Hz}$	-0,0265
Métrica 29	Amplitude do torque para $AVOL=0 - 60 \text{ km/h}$	0,026
Métrica 31	Amplitude de $TVOL$ na mudança de direção - 60 km/h	0,0255
Métrica 5	Tempo de resposta de Taxa de Guinada/ $AVOL @ 1 \text{ Hz}$	-0,0248
Métrica 19	Amplitude do torque para $AY = 0,3 \text{ g}$	-0,0245
Métrica 3	Gradiente do ângulo de deriva posterior	-0,024
Métrica 14	Gradiente de Rolagem/ $AY @ 0,5 \text{ Hz}$	-0,0227
Métrica 2	Gradiente de subesterço na roda	-0,0219

Fonte: Elaboração pelo autor (2025).

A forte presença de métricas relacionadas ao gradiente de rolagem confirma a relevância direta destes parâmetros na percepção subjetiva do comportamento de rolagem, demonstrando a sensibilidade dos avaliadores a este aspecto específico da dinâmica veicular, observa-se também que a percepção está relacionada com os ganhos de taxa de guinada e sua linearidade.

4.5.5.6 Velocidade de rolagem

O parâmetro “Velocidade De Rolagem” (S6) apresentou como principais influenciadoras métricas relacionadas ao torque no volante e dos ganhos de taxa de guinada e aceleração lateral por ângulo de volante. A tabela 11 apresenta as dez métricas mais influentes na resposta da rede neural artificial.

Tabela 11. Importância média para parâmetro S6.

Métrica	Descrição	Importância Média
Métrica 18	TVOL Máximo	0,0368
Métrica 29	Amplitude do torque para AVOL=0 - 60 km/h	0,0313
Métrica 10	Linearidade de Taxa de Guinada/AVOL	0,0306
Métrica 28	Ganho de AY/AVOL - 120 km/h	0,0211
Métrica 23	Amplitude do TVOL @ AY = 0g - 60 km/h	0,0179
Métrica 4	Limite linear de AY	0,0167
Métrica 24	Amplitude do TVOL @ AY = 0g - 120 km/h	0,0158
Métrica 8	Ganho Estático de Taxa de Guinada/AVOL @ 0 Hz	0,0148
Métrica 11	Ganho Estático de AY/AVOL @ 0 Hz	0,0142
Métrica 19	Amplitude do torque para AY = 0,3 g	0,0094

Fonte: Elaboração pelo autor (2025).

As métricas de maior influência sobre S6 obtidas através da análise apontam discordância em relação ao resultado esperado, indicando inconsistência da rede neural na determinação deste parâmetro, visto que era aguardado que o gradiente de taxa de rolagem por ângulo de volante (métrica 15) apresentasse maior contribuição, já que apresentou relações lineares consistentes com esse parâmetro nas análises de correlação apresentadas na seção 4.4.

4.5.5.7 Sensação ao centro

A análise da “Sensação Ao Centro” (S7) revelou a importância de métricas relacionadas ao comportamento próximo à posição neutra do volante e às características de estabilidade direcional. A tabela 12 apresenta as dez métricas mais influentes na resposta da rede neural artificial.

Tabela 12. Importância média para parâmetro S7.

Métrica	Descrição	Importância Média
Métrica 25	Ganho de TVOL/AVOL - 60 km/h	-0,1749
Métrica 26	Ganho de TVOL/AVOL - 120 km/h	-0,1461
Métrica 15	Gradiente de Rolagem/AY @ 1 Hz	-0,1231
Métrica 7	Tempo de reposta de AY/AVOL @ 1 Hz	-0,1037
Métrica 24	Amplitude do TVOL @ AY = 0g - 120 km/h	-0,101
Métrica 3	Gradiente do ângulo de deriva posterior	-0,0806
Métrica 23	Amplitude do TVOL @ AY = 0g - 60 km/h	-0,0795
Métrica 29	Amplitude do torque para AVOL=0 - 60 km/h	-0,0728
Métrica 16	Gradiente de Taxa de Rolagem/AVOL @ 1 Hz	-0,0699
Métrica 4	Limite linear de AY	-0,0695

Fonte: Elaboração pelo autor (2025).

A predominância de métricas relacionadas aos ganhos de TVOL/AVOL e às amplitudes em condições de baixa aceleração lateral corrobora a relevância destes parâmetros para a percepção da marcação do centro da direção.

4.5.5.8 Esforço de direção / progressão

Para a escala “Esforço De Direção / Progressão” (S8), as métricas mais influentes abrangem aspectos relacionados tanto ao torque quanto à progressão da resposta direcional do sistema. A tabela 13 apresenta as dez métricas mais influentes na resposta da rede neural artificial.

Tabela 13. Importância média para parâmetro S8.

Métrica	Descrição	Importância Média
Métrica 31	Amplitude de TVOL na mudança de direção - 60 km/h	-0,0437
Métrica 24	Amplitude do TVOL @ AY = 0g - 120 km/h	0,0367
Métrica 4	Limite linear de AY	0,0364
Métrica 1	Gradiente de subesterço @AVOL	0,0268
Métrica 5	Tempo de resposta de Taxa de Guinada/AVOL @ 1 Hz	-0,0266
Métrica 13	Ganho Dinâmico de Taxa de Guinada/AY @ 1 Hz	-0,0228
Métrica 21	Progressão de TVOL Durante a Curva	0,0186
Métrica 10	Linearidade de Taxa de Guinada/AVOL	-0,0149
Métrica 17	AY @ TVOL Máximo	0,0137
Métrica 11	Ganho Estático de AY/AVOL @ 0 Hz	-0,0132

Fonte: Elaboração pelo autor (2025).

São observados principalmente parâmetros relacionados o torque no volante e sua progressão durante a curva, nota-se também influência significativa de métricas relacionadas a taxa de guinada na percepção do parâmetro S8.

4.5.5.9 Atraso da resposta direcional

Para a escala de “Atraso Da Resposta Direcional” (S9), as métricas mais influentes refletem primariamente aspectos temporais e de linearidade da resposta do sistema. A tabela 14 apresenta as dez métricas mais influentes na resposta da rede neural artificial.

Tabela 14. Importância média para parâmetro S9.

Métrica	Descrição	Importância Média
Métrica 10	Linearidade de Taxa de Guinada/AVOL	0,068
Métrica 29	Amplitude do torque para AVOL=0 - 60 km/h	0,0515
Métrica 22	Tempo de reposta de AVOL/TVOL @ 1 Hz	0,0506
Métrica 2	Gradiente de subesterço na roda	0,0432
Métrica 4	Limite linear de AY	-0,0381
Métrica 16	Gradiente de Taxa de Rolagem/AVOL @ 1 Hz	0,0362
Métrica 17	AY @ TVOL Máximo	-0,0347
Métrica 7	Tempo de reposta de AY/AVOL @ 1 Hz	-0,0343
Métrica 31	Amplitude de TVOL na mudança de direção - 60 km/h	-0,0341
Métrica 12	Ganho Dinâmico de AY/AVOL @ 1 Hz	-0,0341

Fonte: Elaboração pelo autor (2025).

A forte presença de métricas relacionadas à linearidade e aos tempos de resposta confirma a relevância destes parâmetros para a percepção de atraso. Com ênfase na métrica que relaciona o tempo de resposta entre a entrada de torque de volante e a resposta em deslocamento angular (Métrica 22), aparecendo como terceira maior influência, o que demonstra a sensibilidade do avaliador a percepção desta métrica.

5. CONCLUSÕES E CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo central o desenvolvimento de um modelo de rede neural artificial para prever o desempenho subjetivo de veículos, utilizando como base métricas objetivas de dinâmica veicular lateral e de sensação de direção. Para alcançar tal propósito, foram estabelecidos objetivos específicos que guiaram a metodologia e a análise dos dados. A primeira etapa consistiu na obtenção de um robusto banco de dados objetivos, compreendendo 32 métricas extraídas de simulações em software especializado para 57 veículos de diferentes segmentos e fabricantes. Essas métricas abrangeram aspectos da resposta direcional, rolagem da carroceria e sensação de direção.

O tratamento dos dados objetivos, incluiu a remoção de *outliers* e a eliminação de multicolinearidade, resultando na remoção de métricas redundantes. Os dados foram normalizados para garantir a comparabilidade das escalas. A análise de componentes principais (PCA) auxiliou na redução da dimensionalidade e na visualização dos dados, revelando que os primeiros componentes principais conseguiam explicar uma parcela significativa da variância total e estavam associados a macro parâmetros como resposta direcional, dinâmica de rolagem e sensação de direção. Em seguida, procedeu-se ao agrupamento dos veículos com base na similaridade de suas métricas objetivas, utilizando o algoritmo de aprendizado não supervisionado K-Means. Essa etapa permitiu identificar grupos de veículos com comportamentos dinâmicos semelhantes e serviu como base para a seleção de amostras na fase subsequente de avaliação subjetiva.

Vinte e cinco veículos, selecionados com base nos agrupamentos previamente definidos, foram avaliados por um avaliador experiente em um simulador de direção (DiM-150). A avaliação comparativa seguiu uma escala de desempenho subjetiva predefinida, permitindo quantificar as impressões do avaliador. A análise descritiva desses dados subjetivos indicou variações entre os grupos, embora alguns parâmetros tenham apresentado pouca variabilidade dentro de certos *clusters*, sugerindo a necessidade de amostras maiores para análises intragrupo mais detalhadas em trabalhos futuros.

Foram implementadas duas arquiteturas principais de redes neurais artificiais, denominadas RNA_1 e RNA_2, diferenciando-se principalmente no número de camadas ocultas. A análise isolada do Erro Quadrático Médio e R^2 sugeriu inicialmente um desempenho superior de RNA_1 sobre RNA_2. Contudo, a curva de aprendizado de RNA_1 apresentou forte indício de sobreajuste, com a curva de perda de validação em diversas épocas apresentando resultado inferior à curva de validação de treinamento. Em contraste, RNA_2 demonstrou melhor comportamento em termos de generalização de resultados, sendo, portanto, selecionada para as análises subsequentes.

A investigação comparativa entre diferentes abordagens de modelagem constituiu parte fundamental deste estudo. Foram implementados modelos clássicos de aprendizado de máquina como base comparativa para as redes neurais.

Na comparação do desempenho multivariado, as redes neurais demonstraram superioridade significativa em relação aos modelos clássicos, com RNA_2 alcançando uma redução de aproximadamente 40% no erro quadrático médio em comparação com o melhor modelo clássico. Além disso, RNA_2 manteve valores de R^2 mais realistas, indicando melhor equilíbrio entre ajuste aos dados de treinamento e capacidade de generalização. Na análise univariada, realizada para cada parâmetro subjetivo como único target, RNA_2 consistentemente superou os modelos clássicos para todas os parâmetros subjetivos.

Em relação aos parâmetros de resposta direcional (S1-S4), a análise de importância por permutação revelou padrões consistentes de influência das métricas objetivas. A percepção de prontidão de resposta (S1) mostrou-se fortemente associada às características de torque no volante, ao gradiente de subesterço na roda e aos tempos de resposta do sistema, com destaque para a linearidade de resposta da taxa de guinada por ângulo de volante. Para a facilidade em manter a trajetória em curva (S2), observou-se a predominância de métricas relacionadas ao comportamento linear e aos gradientes de subesterço, evidenciando a interconexão entre feedback tátil e controle direcional. A percepção do atraso da resposta do eixo posterior (S3) foi influenciada principalmente por métricas que capturam a dinâmica de resposta do veículo e a coordenação entre os eixos, destacando-se o gradiente do ângulo de deriva posterior e o tempo de resposta de taxa de guinada por aceleração lateral. Já a progressão do ângulo de direção em curvas (S4) mostrou-se dependente das

características lineares e da resposta em frequência do sistema de direção, com influência significativa do gradiente de taxa de rolagem por ângulo de volante.

Quanto aos parâmetros relacionados à rolagem (S5-S6), as análises apresentaram resultados distintos. Para o comportamento de rolagem (S5), as métricas mais influentes refletiram diretamente os aspectos relacionados ao movimento de rolagem do veículo, confirmando a relevância direta destes parâmetros na percepção subjetiva. Observou-se também que a percepção está relacionada com os ganhos de taxa de guinada e sua linearidade, sugerindo uma integração sensorial entre os movimentos de rolagem e guinada. Em contraste, a análise da velocidade de rolagem (S6) apresentou resultados que merecem consideração crítica, com discordância entre as métricas de maior influência identificadas e o resultado esperado, indicando possível inconsistência da rede neural na determinação deste parâmetro específico.

Os parâmetros relacionados à sensação de direção (S7-S9) também apresentaram padrões consistentes de influência. A sensação ao centro (S7) revelou-se influenciada principalmente por métricas relacionadas ao comportamento próximo à posição neutra do volante e às características de estabilidade direcional, com predominância de métricas relacionadas aos ganhos de torque no volante por ângulo de volante e às amplitudes em condições de baixa aceleração lateral. Para o esforço de direção e sua progressão (S8), as métricas mais influentes abrangeram aspectos relacionados tanto ao torque quanto à progressão da resposta direcional do sistema, sugerindo que a percepção do esforço de direção incorpora também aspectos relacionados à resposta dinâmica do veículo. Finalmente, a análise do atraso da resposta direcional (S9) identificou como principais influenciadores aspectos temporais e de linearidade da resposta do sistema, destacando-se a métrica que relaciona o tempo de resposta entre a entrada de torque de volante e a resposta em deslocamento angular.

Dada a quantidade escassa de dados os resultados obtidos com a implementação da rede neural se mostram promissores para a previsão dos parâmetros subjetivos, com exceção da dinâmica de rolagem, para qual deve-se avaliar os resultados após obtenção de mais dados e se necessário realizar a inclusão de novas métricas objetivas para caracterização desse efeito. Nota-se também o alinhamento do avaliador à descrição e percepção dos parâmetros subjetivos.

6. PROPOSTAS DE TRABALHOS FUTUROS

A partir dos resultados apresentados e discutidos propõe-se como sugestão para trabalhos futuros:

- Expansão do conjunto de dados: Aumentar o número de veículos avaliados e a diversidade de configurações para melhorar a robustez dos modelos, permitindo também o desenvolvimento de modelos específicos para cada *Cluster*.
- Utilizar os conhecimentos adquiridos no treinamento de um novo modelo para determinação da avaliação de outros avaliadores.
- Regressão dos parâmetros subjetivos em um único parâmetro classificador da qualidade direcional do veículo.

REFERÊNCIAS

- BARBOSA, F. Desenvolvimento de uma metodologia para avaliação objetiva dos parâmetros do sistema de direção elétrica a partir da avaliação subjetiva do piloto em um simulador de dinâmica veicular. 2022. 162 f. Dissertação — Universidade Federal de Minas Gerais, Belo Horizonte, 2022.
- BLUNDELL, M.; HARTY, D. *Multibody systems approach to vehicle dynamics*. Oxford Burlington, MA: Elsevier Butterworth-Heinemann, 2004.
- BRUCK, L.; HAYCOCK, B.; EMADI, A. A Review of Driving Simulation Technology and Applications. *IEEE Open Journal of Vehicular Technology*, v. 2, p. 1–16, 2021.
- FANG, S.; YU, K. Fine-Tuning Hybrid Physics-Informed Neural Networks for Vehicle Dynamics Model Estimation. *IFAC-PapersOnLine*, v. 58, n. 28, p. 810–815, 2024.
- GIL GÓMEZ, G. L. *et al.* Findings from subjective evaluations and driver ratings of vehicle dynamics: steering and handling. *Vehicle System Dynamics*, v. 53, n. 10, p. 1416–1438, 2015.
- GIL GÓMEZ, G. L. *et al.* Machine learning to classify and predict objective and subjective assessments of vehicle dynamics: the case of steering feel. *Vehicle System Dynamics*, v. 56, n. 1, p. 150–171, 2 jan. 2018.
- GILLESPIE, T. *Fundamentals of Vehicle Dynamics*. Revised ed. [S.l.]: SAE International, 2021. Disponível em: <<https://saemobilus.sae.org/content/R-506/>>. Acesso em: 3 jul. 2023.
- GRUENING, J. *et al.* Driving Simulation. *SAE Transactions*, v. 107, p. 376–385, 1998.
- CARNEIRO, G. Desenvolvimento de metodologia para otimização dinâmica e estrutural de suspensão veicular traseira do tipo eixo de torção. 2019. 226 f. Tese — Universidade Federal de Minas Gerais, Belo Horizonte, 2019.
- HERMANSDORFER, L. *et al.* End-to-End Neural Network for Vehicle Dynamics Modeling. In: 2020 6TH IEEE CONGRESS ON INFORMATION SCIENCE AND TECHNOLOGY (CIST), 5 jun. 2020, Agadir - Essaouira, Morocco. *Anais... Agadir - Essaouira, Morocco: IEEE*, 5 jun. 2020. p. 407–412. Disponível em: <<https://ieeexplore.ieee.org/document/9357196/>>. Acesso em: 30 mar. 2025.
- LEAL, V. Desenvolvimento de metodologia para projeto de suspensões automotivas através de análise subjetiva aplicado em simulador dinâmico veicular. 2024. 222 f. Tese (Doutorado em Sistemas Mecatrônicos) — Universidade de Brasília, Brasília, 2024.
- LI, Q. *et al.* A hybrid physics-data driven approach for vehicle dynamics state estimation. *Mechanical Systems and Signal Processing*, v. 225, p. 112249, fev. 2025.

MARSLAND, S. *Machine Learning: An Algorithmic Perspective*. 2. ed. [S.l.]: Chapman and Hall/CRC, 2014. Disponível em: <<https://www.taylorfrancis.com/books/9781466583337>>. Acesso em: 16 jul. 2024.

MILLIKEN, W. F.; MILLIKEN, D. L. *Race Car Vehicle Dynamics*. [S.l.]: SAE International, 1994.

PAN, Y. *et al.* Machine learning approaches to estimate suspension parameters for performance degradation assessment using accurate dynamic simulations. *Reliability Engineering & System Safety*, v. 230, p. 108950, fev. 2023.


PFEFFER, P. E. *Interaction of vehicle and steering system regarding on-centre handling*. 2006. PhD Thesis – University of Bath, England, 2006.

PFEFFER, P. E.; HARRER, M.; JOHNSTON, D. N. Interaction of vehicle and steering system regarding on-centre handling. *Vehicle System Dynamics*, v. 46, n. 5, p. 413–428, maio 2008.

WANG, X. *et al.* Driver distraction detection based on vehicle dynamics using naturalistic driving data. *Transportation Research Part C: Emerging Technologies*, v. 136, p. 103561, mar. 2022.

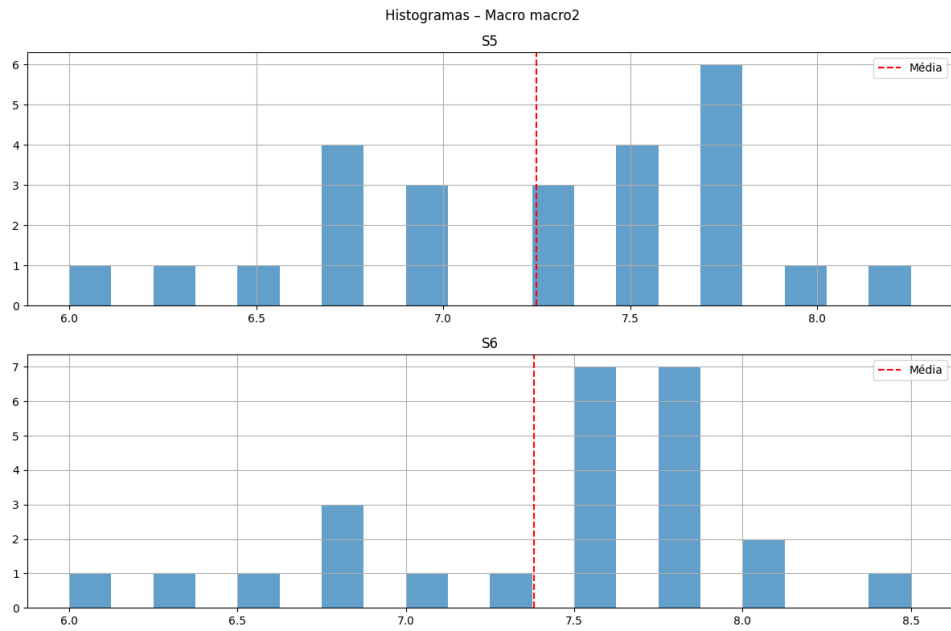
APÊNDICE A - Histogramas gerais dos parâmetros subjetivos obtidos

Figura 37. Histograma Macro 1.




Fonte: Elaboração pelo autor (2025).

Figura 38. Histograma Macro 2.



Fonte: Elaboração pelo autor (2025).

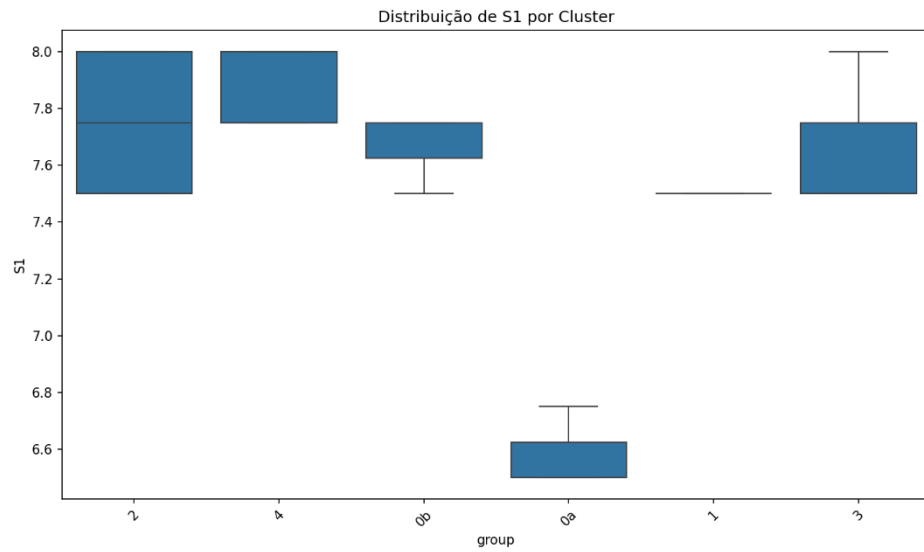
Figura 39. Histograma Macro 3.



Fonte: Elaboração pelo autor (2025).


APÊNDICE B - Distribuição dos parâmetros subjetivos por agrupamento

Figura 40. Distribuição de S1 por Cluster.



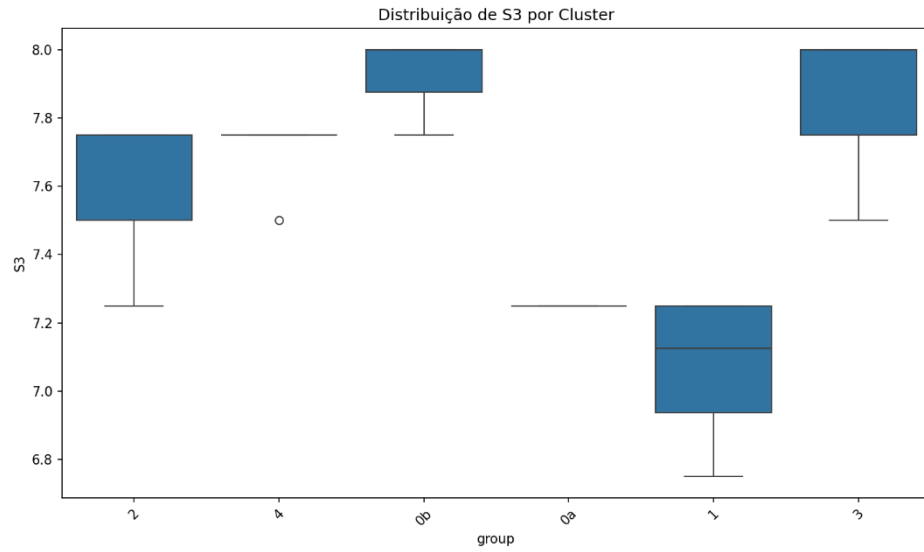
Fonte: Elaboração pelo autor (2025).

Figura 41. Distribuição de S2 por Cluster.




Fonte: Elaboração pelo autor (2025).

Figura 42. Distribuição de S3 por Cluster.




Fonte: Elaboração pelo autor (2025).

Figura 43. Distribuição de S4 por Cluster.




Fonte: Elaboração pelo autor (2025).

Figura 44. Distribuição de S5 por Cluster.




Fonte: Elaboração pelo autor (2025).

Figura 45. Distribuição de S6 por Cluster.




Fonte: Elaboração pelo autor (2025).

Figura 46. Distribuição de S7 por Cluster.



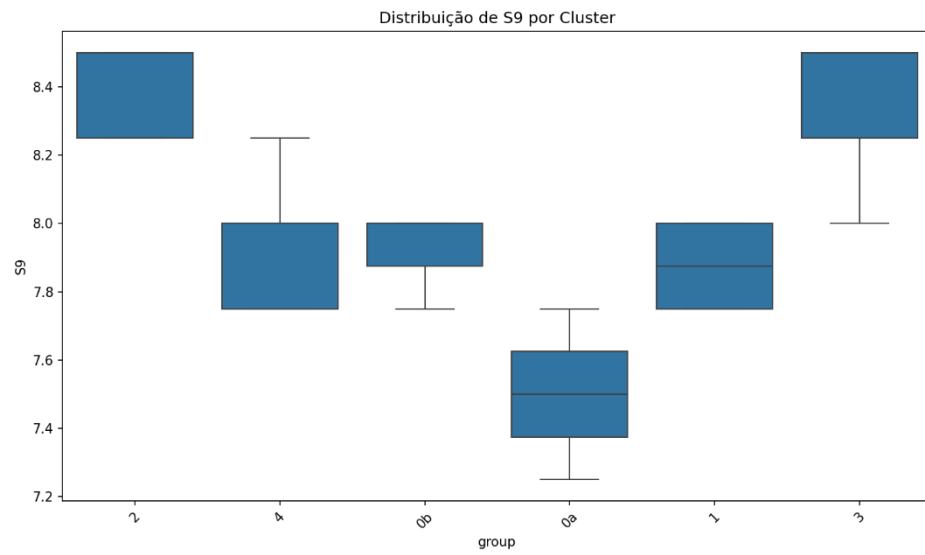
Fonte: Elaboração pelo autor (2025).

Figura 47. Distribuição de S8 por Cluster.



Fonte: Elaboração pelo autor (2025).

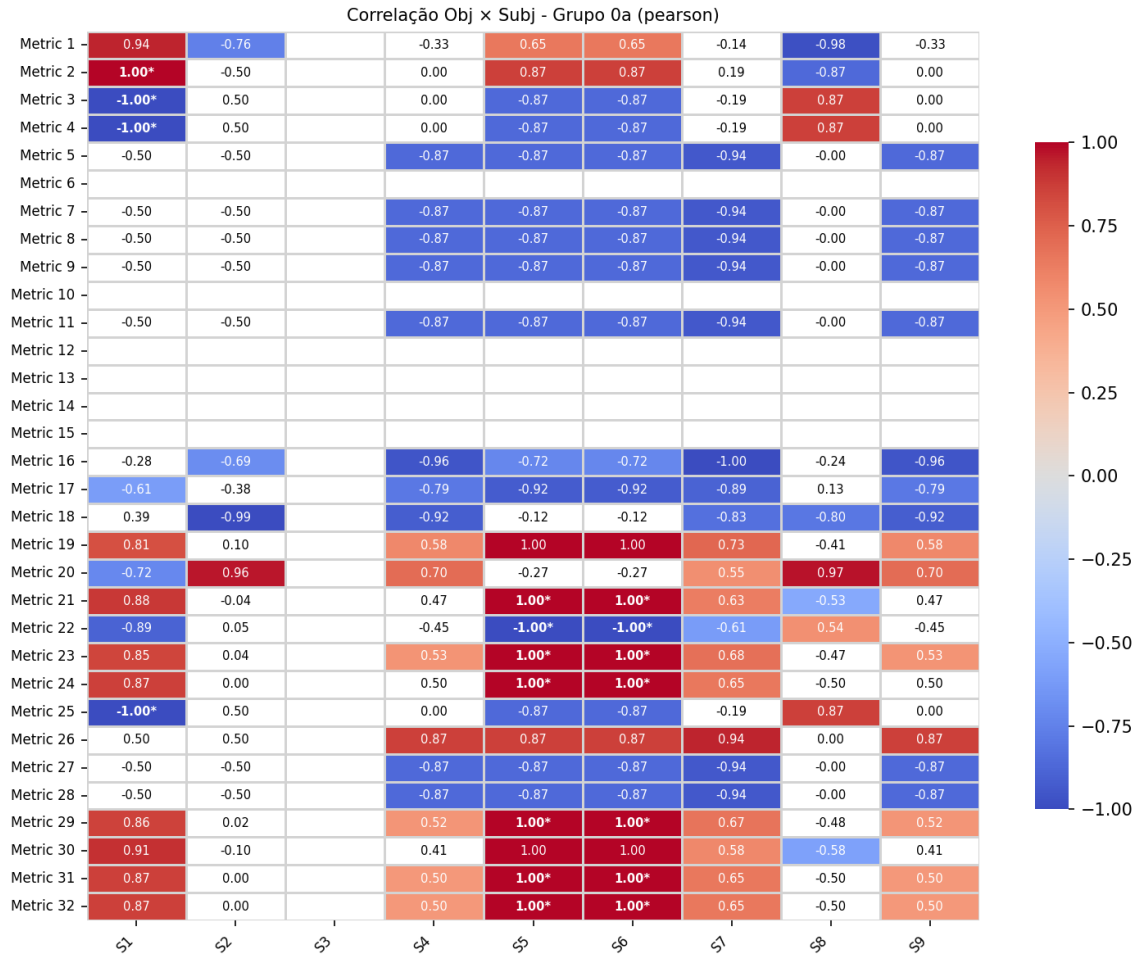
Figura 48. Distribuição de S9 por Cluster.



Fonte: Elaboração pelo autor (2025).

APÊNDICE C - Matrizes de correlação de Pearson para cada agrupamento

Figura 49. Matriz de correlação Grupo 0a.



Fonte: Elaboração pelo autor (2025).

Figura 50. Matriz de correlação Grupo 0b.



Fonte: Elaboração pelo autor (2025).

Figura 51. Matriz de correlação Grupo 1.




Fonte: Elaboração pelo autor (2025).

Figura 52. Matriz de correlação Grupo 2.



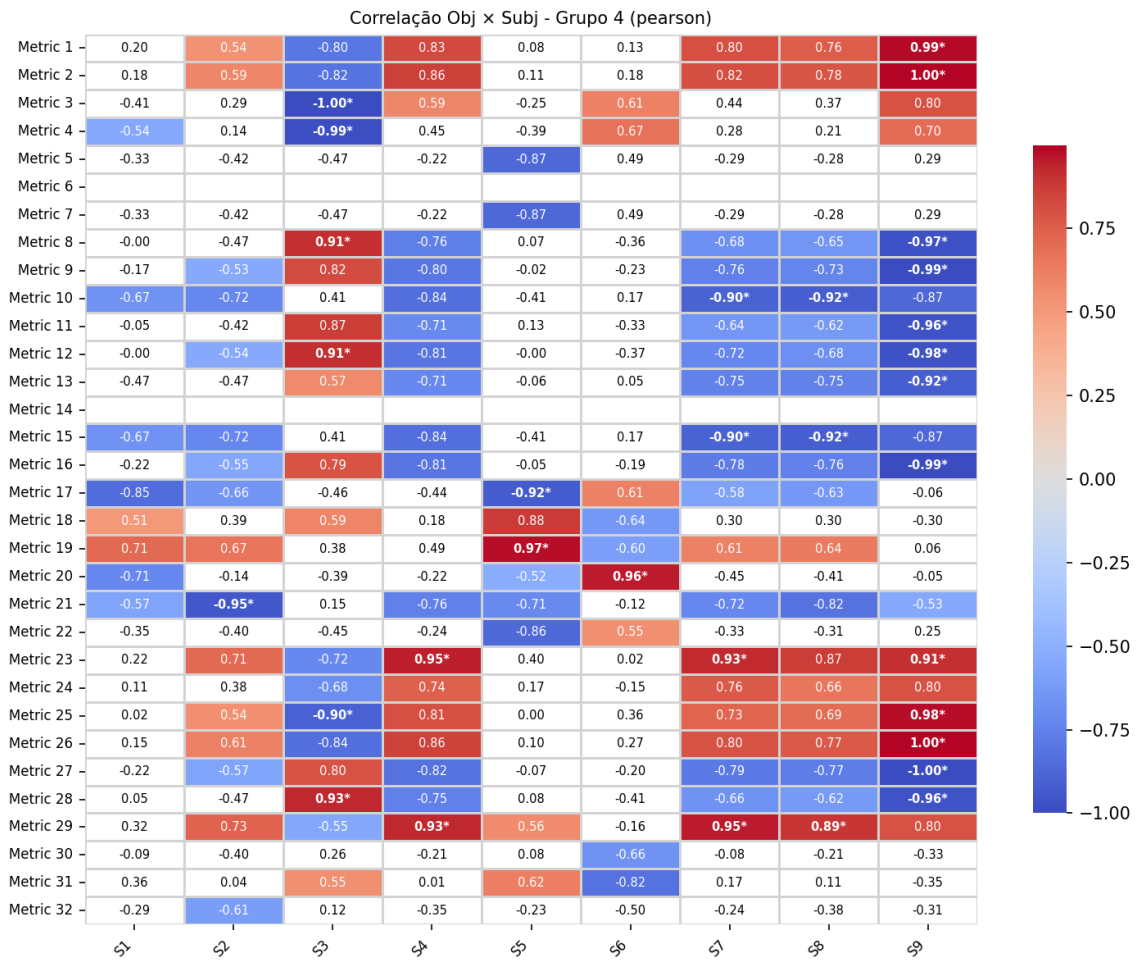
Fonte: Elaboração pelo autor (2025).

Figura 53. Matriz de correlação Grupo 3.



Fonte: Elaboração pelo autor (2025).

Figura 54. Matriz de correlação Grupo 4.



Fonte: Elaboração pelo autor (2025).

APÊNDICE D - Resultados univariados

Tabela 15. Comparativo univariado para target S1.

Modelo	REQM	R ²	Tempo
RNA_2_S1	0,1518	0,8625	55,94
KNN	0,4278	1	0,21
RandomForest	0,4532	0,9328	15,17
Ridge	0,5229	0,7278	0,91
Linear	0,8042	0,8297	0,13

Fonte: Elaboração pelo autor (2025).

Tabela 16. Comparativo univariado para target S2.

Modelo	REQM	R ²	Tempo
RNA_2_S2	0,2353	0,703	54,61
KNN	0,545	1	0,16
RandomForest	0,5457	0,8645	15,16
Ridge	0,6328	0,582	0,91
Linear	0,8535	0,7691	0,12

Fonte: Elaboração pelo autor (2025).

Tabela 17. Comparativo univariado para target S3.

Modelo	REQM	R ²	Tempo
RNA_2_S3	0,2329	0,5183	53,4
KNN	0,4706	1	0,16
RandomForest	0,4891	0,8736	15,1
Ridge	0,5426	0,6214	0,92
Linear	0,8682	0,674	0,12

Fonte: Elaboração pelo autor (2025).

Tabela 18. Comparativo univariado para target S4.

Modelo	REQM	R ²	Tempo
RNA_2_S4	0,2612	0,7606	53,81
KNN	0,5788	1	0,17
Ridge	0,6741	0,8656	0,93
RandomForest	0,6746	0,8314	15,01
Linear	0,6828	0,8939	0,13

Fonte: Elaboração pelo autor (2025).

Tabela 19. Comparativo univariado para target S5.

Modelo	REQM	R ²	Tempo
RNA_2_S5	0,2739	0,754	54,62
KNN	0,4551	1	0,18
RandomForest	0,5199	0,9331	15,09
Ridge	0,6009	0,8459	0,93
Linear	0,6371	0,9127	0,11

Fonte: Elaboração pelo autor (2025).

Tabela 20. Comparativo univariado para target S6.

Modelo	REQM	R ²	Tempo
RNA_2_S6	0,2431	0,8239	54,16
KNN	0,4456	1	0,16
RandomForest	0,5383	0,9426	15,1
Ridge	0,5979	0,8287	0,91
Linear	0,6736	0,9165	0,13

Fonte: Elaboração pelo autor (2025).

Tabela 21. Comparativo univariado para target S7.

Modelo	REQM	R ²	Tempo
RNA_2_S7	0,2811	0,8103	53,95
KNN	0,5724	1	0,18
RandomForest	0,6058	0,9359	15,08
Ridge	0,616	0,7925	0,98
Linear	0,9795	0,8959	0,14

Fonte: Elaboração pelo autor (2025).

Tabela 22. Comparativo univariado para target S8.

Modelo	REQM	R ²	Tempo
RNA_2_S8	0,2083	0,8577	54,14
KNN	0,5554	1	0,15
RandomForest	0,58	0,9074	15,17
Ridge	0,6278	0,9215	0,9
Linear	0,7067	0,9266	0,12

Fonte: Elaboração pelo autor (2025).

Tabela 23. Comparativo univariado para target S9.

Modelo	REQM	R ²	Tempo
RNA_2_S9	0,1342	0,8339	53,69
KNN	0,485	1	0,17
RandomForest	0,5308	0,7552	15,62
Ridge	0,5976	0,5194	0,92
Linear	0,644	0,7879	0,11

Fonte: Elaboração pelo autor (2025).