

Radar Cognitivo: Uma Abordagem Baseada em Gráficos Radar para Identificação de Fadiga e Estilo de Condução

Karolayne S. Azevedo^{*†} , Luísa C. de Souza^{*†} , Marianne Silva[‡] ,

Ivanovitch M. D. da Silva[§] , Marcelo A. C. Fernandes^{*†§¶} 

^{*}InovAI Lab, nPITI/IMD, Universidade Federal do Rio Grande do Norte (UFRN), Natal, RN, Brasil.

[†]Leading Advanced Technologies Center of Excellence (LANCE), nPITI/IMD, UFRN, Natal, RN, Brasil.

[‡]Universidade Federal de Alagoas (UFAL) – Unidade de Ensino Penedo, Penedo, AL, Brasil.

[§]Departamento de Engenharia da Computação e Automação (DCA), UFRN, Natal, RN, Brasil.

[¶]Centro Multiusuário de Bioinformática (BioME) – IMD, UFRN, Natal, RN, Brasil.

karolayneazevedosantos@gmail.com, luisa.souza.103@ufrn.edu.br, marianne.silva@penedo.ufal.br,

ivanovitch.silva@ufrn.br, mfernandes@dca.ufrn.br

Resumo—Este estudo apresenta uma abordagem para identificar estilos de direção e sinais de fadiga com base em parâmetros veiculares. Foram analisados dados de 24 participantes em um simulador de direção, considerando sete variáveis operacionais do veículo. A metodologia envolveu uma análise individual, utilizando o algoritmo K-means aplicado a cada condutor, bem como uma análise global agrupando-os em três perfis: agressivo, moderado e consistente. A área dos gráficos radar foi utilizada como métrica de esforço cognitivo. Os resultados individuais indicaram que áreas maiores nos gráficos estavam associadas a menores taxas de piscadas (média < 50/min), sugerindo fadiga ou sobrecarga cognitiva, enquanto áreas menores corresponderam a taxas de piscadas mais elevadas (> 100/min), indicando estado de alerta. Na análise global, 75% dos participantes foram classificados como agressivos. A abordagem baseada na análise individual demonstrou maior sensibilidade para variações comportamentais sutis. Esses achados reforçam o uso de métodos não invasivos com potencial aplicação em sistemas de assistência ao condutor em tempo real.

Palavras-chave—Comportamento do motorista, detecção de fadiga, análise de gráficos de radar, aprendizagem não supervisionada

I. INTRODUÇÃO

A crescente incorporação de tecnologias de automação veicular tem redesenhado a relação entre motoristas e veículos, atribuindo à máquina a execução de tarefas de direção em determinadas condições. Em veículos semiautônomos, a responsabilidade pela condução é compartilhada: espera-se que o condutor permaneça vigilante e pronto para reassumir o controle a qualquer momento [1]. Essa exigência cognitiva contínua, mesmo em longos períodos de passividade, levanta preocupações relevantes do ponto de vista da segurança viária, sobretudo durante as transições entre os modos automatizado e manual [2].

Nesse contexto, o conceito de Consciência Situacional (*Situation Awareness* – SA) torna-se fundamental, pois se refere à capacidade do motorista de perceber, compreender

e antecipar eventos no ambiente dinâmico da condução [3], [4]. Evidências mostram que a perda da SA, frequentemente associada à fadiga, distração ou complacência tecnológica, compromete a retomada segura do controle do veículo [5], [6]. Isso torna a identificação precoce de mudanças no estado do condutor um elemento crítico para prevenir acidentes.

Apesar dos avanços em sistemas de monitoramento, ainda é desafiador detectar alterações comportamentais sutis e graduativas que indicam sobrecarga cognitiva ou declínio da atenção [7]. A maioria das abordagens atuais baseia-se em modelos generalistas, que desconsideram a variabilidade individual dos motoristas, e em técnicas supervisionadas que exigem dados rotulados limitando sua aplicabilidade em contextos reais, onde o comportamento humano é dinâmico e multifatorial [8].

Este estudo busca preencher esse *gap* propondo uma abordagem individualizada e não supervisionada para análise do comportamento de direção. A proposta considera a variação intraindividual como chave para detectar transições comportamentais relevantes, com potencial aplicação em sistemas inteligentes de assistência veicular adaptativos.

Como principais contribuições, este trabalho: (1) caracteriza perfis de direção com base em sete variáveis veiculares críticas, relacionadas ao esforço cognitivo e à estabilidade do comportamento; (2) demonstra que é possível inferir estados como fadiga e vigilância por meio de parâmetros não invasivos; e (3) valida uma métrica híbrida que associa a intensidade de uso dos recursos veiculares expressa pela área de gráficos radar à taxa de piscadas por minuto, um marcador fisiológico associado à carga mental.

Um dos diferenciais desta pesquisa está na utilização de um *dataset* exclusivo, obtido a partir do experimento LAS (*Low Arousal and Sleepiness LAS*) [9], [10], realizado em ambiente de simulação realista no contexto do projeto europeu HADRIAN, com participação da Universidade Federal do Rio Grande do Norte (UFRN) e da Universidad de Granada (UGR). Em contraste com abordagens convencionais, o estudo

adota a área de gráficos radar, derivada de sete parâmetros veiculares — como indicador do estado do motorista, partindo do pressuposto de que maiores áreas refletem maior variabilidade no controle do veículo, associada a esforço cognitivo elevado e possíveis sinais de fadiga.

Este artigo está organizado da seguinte forma: a Seção II apresenta a revisão da literatura pertinente. A Seção III descreve a metodologia utilizada. Os resultados das análises individuais e globais são apresentados e discutidos nas Seções IV e V, respectivamente. Por fim, a Seção VI resume as conclusões do trabalho.

II. TRABALHOS RELACIONADOS

O uso de técnicas de aprendizado de máquina, especialmente algoritmos de agrupamento como o K-means, tem sido amplamente explorado na identificação de estilos de direção e estados de fadiga. Estudos recentes demonstram que a análise de dados veiculares e fisiológicos permite uma caracterização mais precisa do comportamento dos motoristas, contribuindo para a segurança viária.

Zhang et al. [1] propuseram uma abordagem multimodal para detectar fadiga em motoristas de caminhões-tanque, integrando dados de eletrocardiograma, rastreamento ocular e variáveis operacionais. O método utilizou K-means para agrupar os dados em quatro níveis de fadiga, cujos rótulos foram posteriormente empregados em classificadores supervisionados (Random Forest e SVM). Os resultados obtiveram uma acurácia de 92,6%, oferecendo suporte teórico robusto para a avaliação do estado do condutor.

Yarlagadda e Pawar [11] aplicaram o algoritmo K-means para identificar padrões de condução com base em dados de velocidade, aceleração e desaceleração de 42 motoristas profissionais. Os condutores foram agrupados em três categorias, cautelosos, moderados e agressivos, e os resultados revelaram que o nível de agressividade não é constante, variando conforme o regime de condução.

Chen et al. [12] propuseram um modelo de avaliação de risco baseado em quatro indicadores derivados de dados longitudinais e laterais: estabilidade lateral, estabilidade longitudinal, risco de seguimento e risco de mudança de faixa. Utilizando K-means, os comportamentos foram classificados em quatro categorias: perigoso, agressivo, seguro e conservador. Os resultados do modelo foram compatíveis com avaliações periciais, indicando potencial para aplicação em tempo real.

Mohammadnazar et al. analisaram mais de 27 milhões de observações oriundas de veículos conectados, agrupando os dados em três estilos de condução: agressivo, normal e calmo. As variáveis consideradas incluíram acelerações e velocidades longitudinais e laterais. Os autores utilizaram gráficos radar para representar os agrupamentos e observaram maior ocorrência de comportamentos agressivos em vias comerciais, além de proporem uma Pontuação de Condução para avaliação comparativa entre motoristas.

Silva et al. [13] apresentaram uma arquitetura online em três camadas para detecção de eventos de condução e caracterização do perfil do motorista. Utilizaram variáveis

como RPM, velocidade, posição do acelerador e carga do motor em conjunto com os algoritmos TEDA e AutoCloud (em duas variantes: k-fixa e janelado). Os perfis foram visualizados por meio de gráficos radar, e os condutores foram classificados em comportamentos moderados, tênues e agressivos.

Adavikottu e Velaga [14] investigaram fatores associados ao comportamento agressivo em 405 motoristas indianos, utilizando dados demográficos, condições do veículo e histórico de direção. A técnica K-means foi aplicada às pontuações da Escala de Direção Agressiva (ADS), classificando os condutores em três grupos. O estudo destacou que variáveis como idade, experiência e fatores ambientais influenciam significativamente o comportamento ao volante.

Em comparação com os estudos citados, a presente proposta se destaca por adotar uma análise individualizada baseada em dados de direção associados a indicadores fisiológicos objetivo, como a taxa de piscadas — sem depender de rótulos supervisionados. Além disso, a técnica proposta utiliza representações visuais por meio de gráficos radar para capturar o esforço do motorista, permitindo identificar três estilos distintos de direção: **consistente, agressivo, e agressivo e variável**. A integração de múltiplos parâmetros e a abordagem personalizada conferem maior sensibilidade na detecção de comportamentos de risco e potenciais sinais de fadiga, superando metodologias baseadas exclusivamente em variáveis como aceleração e velocidade.

III. METODOLOGIA

Este estudo investiga a relação entre o estado do condutor e o uso dos recursos veiculares, com foco na influência do cansaço sobre o comportamento de direção. Os dados foram obtidos a partir do experimento LAS (*Low Arousal and Sleepiness* – LAS), concebido para avaliar estados de excitação e sonolência de diferentes perfis de motoristas. O experimento possui duração aproximada de três horas, iniciando-se com 1h30 de direção automatizada, seguida de 1h30 de direção manual. Entre essas fases, há uma transição de 15 segundos e, no último minuto, é realizada uma medição final de tempo de reação com limite de velocidade de 130 km/h. A Figura 1 ilustra a linha temporal do experimento e as transições entre os modos de condução.

No LAS, participaram duas categorias de motoristas:

- **Idosos:** 31 participantes, com idades entre 65 e 81 anos e pelo menos 25 anos de experiência em direção. Foram excluídos 8 participantes das análises de ECG, 4 das de temperatura e 3 das análises de movimentos oculares.
- **Condutores da área comercial:** 24 participantes, sendo 21 homens e 3 mulheres, com idades entre 27 e 57 anos. Foram excluídos 3 participantes das análises de EDA, 5 das de temperatura e 3 das análises de movimentos oculares.

Entretanto, devido a problemas de inconsistência nos dados, apenas 24 participantes no total dos dois grupos foram efetivamente utilizados nesta análise.

Durante a simulação, foram coletados dados neurocomportamentais, sinais psicofisiológicos (ECG, EDA, EMG, BVP




Fig. 1: Visão geral do experimento LAS (*Low Arousal and Sleepiness*). À esquerda, são apresentadas as categorias de participantes, enquanto a linha temporal ilustra as fases do experimento, destacando as transições entre condução automatizada e manual.

e rastreamento ocular), variáveis operacionais do veículo e Anotações Comportamentais [15]: informações qualitativas sobre eventos como expressões faciais (bocejos, caretas), gestos manuais (coçar o rosto, mãos fora do volante), posturas corporais e ocorrências de colisões ou quase-colisões. No entanto, para esta análise, consideraram-se apenas os parâmetros veiculares relacionados à condução manual, como aceleração, velocidade e posição do volante. Esses dados foram amostrados a 120, Hz, totalizando aproximadamente 678,100 amostras por indivíduo.

Sete variáveis veiculares foram selecionadas com base na literatura [1], [16], por sua relevância na identificação do esforço cognitivo, controle dinâmico e estabilidade de direção [17]–[19]. As variáveis consideradas foram: aceleração resultante, aceleração no eixo X, aceleração do pedal, posição do volante, velocidade, deslocamento lateral em relação ao centro da pista e mudanças de faixa. Para todas as variáveis, foi utilizado o desvio padrão como medida de análise, com exceção das mudanças de faixa, para as quais foi realizada a contagem de ocorrências. Essa escolha foi feita não apenas com base na revisão bibliográfica, mas também após análises exploratórias, nas quais outras variáveis apresentaram baixa expressividade nos gráficos radar, reforçando a adequação do conjunto de parâmetros selecionado para representar o comportamento de direção, conforme ilustrado na Figura 3.

Antes da aplicação do modelo, os dados foram normalizados. A base de cada participante foi dividida em 80% para treinamento (542,480 amostras) e 20% para teste (135,620 amostras), visando garantir a consistência dos agrupamentos. Para identificação de padrões comportamentais, foi aplicado o algoritmo K-Means [20], configurado com: `init=k-means++`, `n_init=1000` (1000 inicializações independentes) e até `max_iter=1000` iterações por inicialização.

Para a visualização dos agrupamentos, foi empregada a técnica t-SNE (*t-Distributed Stochastic Neighbor Embedding*),

que projeta dados de alta dimensão em um espaço bidimensional de maneira a preservar a estrutura local dos dados, ou seja, mantendo a semelhança entre pontos próximos no espaço original em sua representação visual. Essa característica torna o t-SNE especialmente útil para identificar padrões de proximidade e isolamento entre clusters, o que é mais difícil de observar com técnicas lineares como o PCA. Estudos recentes mostram que o t-SNE geralmente supera métodos como UMAP quando o objetivo é preservar a estrutura local e revelar subdivisões sutis nos agrupamentos, embora sacrifique a preservação global das distâncias entre clusters [21].

Após a geração dos clusters para cada participante, foi realizada a estimativa do esforço cognitivo associado à direção por meio da área dos gráficos radar. Esta métrica foi construída com os valores normalizados representativos de cada cluster, utilizando a normalização min-max no intervalo [0, 1], garantindo a comparabilidade entre as variáveis com diferentes escalas. A área foi calculada conforme a Equação 1:

$$A = \frac{1}{2} \times \left| \sum_{i=1}^n (x_i y_{i+1} - x_{i+1} y_i) \right| \times \sin \left(\frac{2\pi}{n} \right) \quad (1)$$

Em que x_i e y_i são as coordenadas projetadas das variáveis normalizadas. Áreas maiores refletem maior variabilidade e esforço cognitivo [22]. A Figura 2 exemplifica um gráfico radar.




Fig. 2: Exemplo genérico de um gráfico radar.

Como métrica fisiológica auxiliar, utilizou-se a taxa de piscadas por minuto, calculada pela Equação 2:

$$R_b = \frac{\sum_{i=1}^n B_i}{T} \quad (2)$$

Sendo B_i o número de piscadas por imagem, n o total de imagens e T o tempo total em minutos.

Por fim, foram consideradas duas hipóteses estatísticas:

- H_0 : não há correlação entre área radar e comportamento do motorista;
- H_1 : existe associação positiva entre maior uso dos recursos veiculares e sinais de fadiga.




Fig. 3: Fluxo metodológico geral do experimento.

IV. RESULTADOS

A. Análises Individuais

Para identificar variações comportamentais sutis que poderiam ser mascaradas em abordagens agregadas, este estudo adotou inicialmente uma análise individualizada. Nessa etapa, o algoritmo K-means foi aplicado separadamente para cada participante, segmentando seus dados em dois *clusters*. Essa estratégia visa capturar variações intraindividuais ao longo do experimento, especialmente aquelas associadas à fadiga, distração ou mudanças no estilo de direção.

Os gráficos radar apresentados nas Figuras 4a a 4d ilustram essas variações, permitindo a comparação direta entre os dois *clusters* de cada motorista. Cada polígono representa a intensidade de uso dos recursos veiculares com base em sete variáveis críticas. Diferenças significativas entre os clusters apontam para momentos de maior esforço físico ou cognitivo durante a condução.

Essa modelagem personalizada apresenta duas contribuições principais. Primeiramente, respeita as particularidades comportamentais de cada condutor, reconhecendo que reações a estímulos de condução podem variar mesmo em condições padronizadas. Em segundo lugar, fornece uma base sólida para comparação com o modelo geral.

A análise conjunta, por sua vez, permitiu a identificação de tendências populacionais por meio da agrupação de todos os participantes em três perfis gerais de direção. No entanto, observou-se que essa abordagem global pode ocultar comportamentos transitórios ou específicos que só se revelam na análise individual.

Assim, a combinação das duas abordagens (individual e coletiva) permite uma compreensão mais abrangente e precisa do comportamento de direção. A identificação de estilos personalizados, com variações nos padrões de uso dos parâmetros veiculares, representa um avanço importante para o desenvolvimento de sistemas adaptativos mais sensíveis e eficazes em ambientes de condução semiautônoma.

A Tabela I apresenta os valores de área dos clusters 0 e 1 para cada participante, destacando o cluster dominante, aquele que apresentou maior área, e o estilo de direção inferido com base na variabilidade dos parâmetros veiculares. Embora os valores de *Silhouette Score* obtidos neste estudo variem entre 0,050 e 0,156, indicando uma separação moderada entre os grupos, esses resultados são coerentes com análises de comportamento humano, nas quais a alta variabilidade intraindividual tende a reduzir a separabilidade absoluta entre clusters. A classificação dos estilos foi realizada de forma

empírica, considerando o grau de dispersão nas variáveis monitoradas.

De maneira geral, participantes cujo cluster dominante apresentou áreas significativamente maiores foram classificados com estilo *agressivo*, indicando um uso mais intenso e variável dos recursos do veículo. Indivíduos com áreas intermediárias e próximas entre os dois agrupamentos foram classificados como *moderados*, enquanto aqueles com áreas consistentemente baixas, refletindo baixa variabilidade entre os parâmetros, foram associados ao estilo *consistente*.

TABLE I: Resumo das áreas por indivíduo, estilo de direção e Silhouette Score


ID	Área Cluster 0	Área Cluster 1	Cluster Dominante	Estilo Inferido	Silhouette Score
53	0,345	0,412	1	Consistente	0,056
55	0,683	0,291	0	Agressivo	0,076
57	0,636	0,593	0	Agressivo	0,100
61	0,589	0,478	0	Agressivo	0,064
62	0,211	0,622	1	Agressivo	0,089
63	0,431	0,589	1	Agressivo	0,073
64	0,602	0,517	0	Agressivo	0,083
66	0,528	0,544	1	Moderado	0,127
67	0,511	0,539	1	Moderado	0,053
68	0,607	0,504	0	Agressivo	0,070
69	0,578	0,486	0	Agressivo	0,106
71	0,672	0,498	0	Agressivo	0,091
72	0,516	0,623	1	Agressivo	0,076
73	0,594	0,451	0	Agressivo	0,156
74	0,681	0,398	0	Agressivo	0,122
75	0,642	0,475	0	Agressivo	0,072
76	0,598	0,601	1	Moderado	0,102
78	0,655	0,487	0	Agressivo	0,066
79	0,621	0,512	0	Agressivo	0,068
80	0,603	0,534	0	Agressivo	0,072
82	0,586	0,544	0	Moderado	0,050
83	0,611	0,529	0	Agressivo	0,099
85	0,654	0,499	0	Agressivo	0,069
91	0,588	0,428	0	Agressivo	0,108

Observa-se que a maior parte dos participantes apresentou o cluster 0 como dominante, o que pode indicar que esse agrupamento reflete estados de direção mais exigentes, possivelmente associados à fadiga ou a estilos mais reativos. Participantes como os IDs 55, 74, 75 e 85 apresentaram áreas superiores a 0,65, sugerindo comportamentos de condução altamente intensos.


Em contraste, o ID 53 foi o único classificado como *consistente*, com áreas relativamente reduzidas e próximas entre si, evidenciando uma condução mais estável ao longo do experimento.

V. RESULTADOS E DISCUSSÕES BASEADOS EM ANÁLISES INDIVIDUAIS


A análise individual dos gráficos radar evidenciou variações significativas nos padrões de direção entre os participantes, mesmo sob condições experimentais padronizadas. Para cada indivíduo, os dados de condução manual foram segmentados em dois *clusters* por meio do algoritmo K-Means, permitindo identificar transições sutis no comportamento, possivelmente associadas à fadiga, distração ou oscilação de atenção.




(a) Indivíduo 55: Área C0 = 0,493 / C1 = 0,281



(b) Indivíduo 71: Área C0 = 0,4818 / C1 = 0,3948



(c) Indivíduo 74: Área C0 = 0,3624 / C1 = 0,2145



(d) Indivíduo 85: Área C0 = 0,4058 / C1 = 0,3294

Fig. 4: Gráficos radar dos indivíduos 55, 71, 74 e 85, evidenciando maior uso de recursos veiculares no cluster dominante.

As Figuras 4a a 4d ilustram que o *cluster* com maior área está geralmente relacionado a um uso mais intenso dos parâmetros veiculares, refletindo maior esforço cognitivo. O indivíduo 55, por exemplo, apresenta discrepâncias marcantes em variáveis como `ACCELERATION_RESULT_STD` e `STD_STEERING_WHEEL_ANGLE`, sugerindo um estilo de direção mais agressivo. Padrões semelhantes são observados nos indivíduos 74 e 85.

Os principais parâmetros que diferenciaram os *clusters* foram `ACCELERATION_RESULT_STD`, `STD_LANE_SHIFT` e `STD_STEERING_WHEEL_ANGLE`, seguidos por `ACCELERATION_PEDAL_STD` e `LANE_CHANGES`. Esses indicadores mostraram-se sensíveis à instabilidade e ao esforço na direção.

A Tabela I confirma essas observações, destacando que a maioria dos *clusters* dominantes apresentou áreas superiores a 0,6, o que pode indicar maior carga cognitiva ou fadiga. Em contraste, o ID 53 mostrou áreas equilibradas e menores, associadas a um estilo mais estável.

Esse tipo de modelagem personalizada é mais eficaz que abordagens globais para identificar padrões comportamentais individuais. Além de auxiliar na inferência de estados críticos como fadiga e desatenção, os gráficos radar oferecem uma visualização intuitiva dos perfis, o que favorece aplicações práticas em sistemas de assistência veicular adaptativos.

As análises subsequentes incluirão histogramas de velocidade e taxas de piscadas por minuto, aprofundando a relação entre variabilidade de direção, esforço cognitivo e sinais fisiológicos de fadiga.

A. Discussões

A análise integrada entre área dos gráficos radar e taxa de piscadas por minuto forneceu evidências sobre o estado de alerta, esforço cognitivo e estilo de direção dos participantes. Quatro padrões principais foram observados:

- **Baixa taxa de piscadas e possível fadiga:** IDs como 55, 57, 62, 69, 79 e 91 apresentaram menos de 50 piscadas por minuto, especialmente nos clusters com maior área, sugerindo sobrecarga cognitiva ou vigilância reduzida.
- **Taxas intermediárias e adaptação ativa:** Participantes como 72, 82, 83, 67, 53, 63, 61 e 66 exibiram de 50 a 100 piscadas por minuto. Na maioria dos casos, maior área também correspondeu a maior taxa de piscadas, indicando esforço adaptativo diante de condições exigentes.
- **Alta taxa de piscadas e elevado estado de alerta:** IDs 71 e 76 mantiveram mais de 100 piscadas por minuto mesmo com alta variabilidade, o que sugere maior engajamento e menor fadiga.
- **Casos ambíguos:** Alguns indivíduos (74, 78, 80 e 85) apresentaram alta taxa de piscadas combinada com grandes áreas, indicando possíveis estratégias compensatórias ou influência de fatores individuais, como experiência prévia ou perfil fisiológico.

Como os dados foram coletados em ambiente simulado, a ausência de riscos reais pode ter influenciado comportamentos

mais agressivos ou menos cautelosos, mesmo em situações indicativas de fadiga.

A Tabela II mostra a classificação dos participantes em três grupos principais, com base na área dos clusters e na variabilidade dos parâmetros:

- **Consistente e Estável** (IDs 76, 78, 79, 80, 82, 83, 85, 91): menor variabilidade e maiores taxas de piscadas, associadas a menor fadiga.
- **Moderado** (IDs 67, 68, 69, 71, 72, 73, 74, 75): variabilidade intermediária e indicadores compatíveis com estado funcional de alerta.
- **Agressivo com Mudanças de Faixa e Acelerações Extremas** (IDs 53, 55, 57, 61, 62, 63, 64, 66): maior variabilidade e menores taxas de piscadas, sugerindo esforço cognitivo elevado ou fadiga recorrente.

A relação entre variabilidade comportamental e indicadores fisiológicos mostra-se promissora para sistemas de assistência veicular. A integração desses dados fortalece modelos preditivos de fadiga e permite intervenções em tempo real, como alertas personalizados. Conclui-se que abordagens multivariadas e centradas no indivíduo são essenciais para uma identificação precisa de riscos na condução. Com base na área dos gráficos radar e nos parâmetros dominantes, os participantes foram agrupados em três perfis comportamentais:

- **Agressivo com Aceleração e Mudança de Faixa:** IDs 53, 55, 57, 61, 62, 63, 64, 66.
- **Moderado:** IDs 67, 68, 69, 71, 72, 73, 74, 75.
- **Consistente e Estável:** IDs 76, 78, 79, 80, 82, 83, 85, 91.

B. Relação entre Estilo de Direção e Taxa de Piscadas

Ao correlacionar os estilos de direção classificados na Tabela II com as taxas médias de piscadas observadas nos *clusters* de cada indivíduo, emergem padrões consistentes que fortalecem a hipótese de que o comportamento de direção está intimamente relacionado ao estado de alerta ou fadiga do condutor.

Observa-se que os participantes do grupo **Agressivo com Mudanças de Faixa e Acelerações Extremas** apresentam, em sua maioria, taxas de piscadas reduzidas, frequentemente abaixo de 50 por minuto, como é o caso dos IDs 55, 57, 62 e 69. Essa baixa frequência de piscadas, associada a áreas elevadas nos gráficos radar, pode indicar fadiga latente ou esforço cognitivo acentuado para manter a performance de direção, ainda que sob ambiente simulado. A resposta visual reduzida pode refletir menor vigilância e menor resposta a estímulos, elementos críticos para a segurança na condução.

Por outro lado, motoristas classificados no grupo **Consistente e Estável**, como os IDs 76, 80 e 85, exibiram taxas médias de piscadas superiores a 100 por minuto, associadas a áreas menores nos gráficos radar. Esse padrão indica um controle mais equilibrado dos recursos do veículo e uma maior responsividade fisiológica, sugerindo um estado de alerta mais sustentável ao longo do experimento.

O grupo **Moderado** apresentou padrões mais heterogêneos, com taxas de piscadas variando entre 50 e 100 por minuto.

Essa faixa intermediária pode ser indicativa de estados transitórios de fadiga leve ou de adaptação à tarefa, o que é compatível com o próprio perfil técnico do grupo: condutores com variabilidade moderada nos parâmetros de direção, sem extremos agressivos nem padrões totalmente estáveis.

Casos como os dos IDs 74 e 78 chamam atenção por apresentarem alta taxa de piscadas (superior a 100), mas menor frequência no *cluster* de maior área. Isso reforça a necessidade de interpretar os dados fisiológicos em conjunto com os dados comportamentais, evitando generalizações. Pode haver, nesses casos, elementos como variabilidade individual, estilo de piscar ou mesmo estratégias compensatórias adotadas durante a tarefa.

A análise integrada desses dois domínios — comportamento de direção e estado fisiológico — destaca a complexidade da fadiga e a importância de abordagens multifatoriais para sua identificação. A taxa de piscadas, apesar de ser um indicador confiável, deve ser interpretada no contexto dos padrões de direção observados para fornecer uma avaliação mais robusta e personalizada do estado do condutor.

C. Modelo Geral

Com o objetivo de identificar perfis globais de comportamento de direção, foi construído um modelo geral a partir da união dos dados de todos os indivíduos, aplicando-se o algoritmo K-Means para agrupar os participantes em três *clusters* distintos, conforme ilustrado na Figura 4.

O **Cluster 0** foi classificado como o *Estilo de Direção Agressivo*, apresentando a maior área média (0,7813) entre os grupos. Esse perfil foi caracterizado por elevada variabilidade em variáveis como aceleração, ângulo do volante e velocidade, indicando comportamentos como mudanças bruscas de faixa e uso intenso do pedal de aceleração.

O **Cluster 1**, por sua vez, representou o *Estilo de Direção Consistente e Cauteloso*, com a menor área média (0,2485), refletindo baixa variabilidade nos parâmetros analisados. Os motoristas desse grupo apresentaram padrões estáveis e previsíveis de condução, com variações suaves na velocidade e aceleração e poucas mudanças de faixa.

O **Cluster 2** correspondeu ao *Estilo de Direção Moderado*, apresentando uma área intermediária (0,5510), com comportamento de direção equilibrado, posicionado entre os extremos dos clusters 0 e 1. Os indivíduos desse grupo demonstraram variações controladas nos parâmetros de condução, sem picos de agressividade ou excesso de cautela.

A partir da análise, foi possível associar cada grupo de indivíduos a um dos perfis de direção identificados. No **Cluster 0** (Agressivo), foram incluídos os indivíduos com IDs 55, 57, 61, 66, 76 e 80. O **Cluster 1** (Consistente e Cauteloso) agrupou os IDs 53, 62, 68, 69, 79, 85 e 91. Já o **Cluster 2** (Moderado) contou com os participantes de IDs 55, 61, 68, 74 e 78.

A aplicação do K-Means em todos os dados visou identificar padrões gerais e agrupamentos consistentes entre indivíduos com características similares de direção. Essa abordagem favorece a escalabilidade da análise, sendo especialmente útil para conjuntos de dados volumosos, além de permitir

TABLE II: Classificação dos indivíduos com base em estilos de direção, condições de condução e fadiga do motorista.

Grupo	IDs	Características
Direção Consistente e Estável	76, 78, 79, 80, 82, 83, 85, 91	Padrões de direção consistentes com pequenas variações em todos os parâmetros. As áreas dos clusters são similares, indicando controle estável sobre aceleração, mudanças de faixa e ângulos de direção.
Moderado	67, 68, 69, 71, 72, 73, 74, 75	Comportamento de direção agressivo e variável. Altas variações em acelerações e mudanças de faixa.
Agressivo e Variável com Mudanças de Faixa e Acelerações Extremas	53, 55, 57, 61, 62, 63, 64, 66	Estilo de direção variável e agressivo. Mudanças frequentes de faixa e acelerações acentuadas. Áreas maiores correspondem a esses comportamentos.




Fig. 5: Modelo geral com dados de todos os indivíduos para os três clusters.

comparações uniformes entre grupos. No entanto, é importante reconhecer que esse método pode não capturar certas nuances individuais que são perceptíveis apenas em análises mais granulares.

Os estilos de direção apresentados na Tabela II foram inicialmente definidos com base em análises individualizadas, utilizando dois *clusters* por participante, com foco nas áreas dos gráficos radar e na interpretação dos principais parâmetros. Essa abordagem personalizada permitiu uma caracterização detalhada do comportamento de cada condutor, mas não favorece a identificação de padrões coletivos.

Diferenças entre os resultados das análises individual e global podem ocorrer devido à variação nos critérios de agrupamento, à natureza dos dados ou às abordagens metodológicas adotadas. Enquanto a análise individual considera particularidades específicas de cada participante, o modelo geral baseado em K-Means busca generalizações a partir de critérios uniformes.

Portanto, a análise individual é mais adequada para capturar comportamentos específicos e particularidades do estilo de direção de cada motorista, enquanto a abordagem global com K-Means se mostra eficaz na identificação de tendências populacionais e na padronização de perfis em escala mais ampla.

D. Comparativo com o Modelo Geral de Três Clusters

A partir da comparação entre a análise individual e o modelo geral apresentado na Seção V-C, observa-se uma tendência de correspondência entre os indivíduos classificados

como agressivos nas análises individuais e aqueles alocados no **Cluster 0** do modelo geral. Ainda assim, divergências pontuais reforçam a importância da abordagem personalizada para captura de padrões sutis que não são totalmente visíveis na análise agregada.

Esses achados reforçam a hipótese alternativa (H_1), indicando que o comportamento de direção está relacionado ao maior uso dos recursos do veículo, e que tal relação pode ser captada tanto de forma agregada quanto individual, sendo esta última mais sensível a variações intraindividuais.

VI. CONCLUSÃO

Este estudo propôs uma abordagem híbrida e multivariada para identificar estilos de direção e inferir estados de fadiga em motoristas por meio da análise combinada de parâmetros veiculares e indicadores fisiológicos. A partir da aplicação do algoritmo K-means.

A análise individual revelou-se mais sensível na detecção de variações comportamentais intraindividuais, respeitando a singularidade de cada condutor ao longo do tempo. Por outro lado, a análise global permitiu identificar padrões populacionais relevantes, úteis para aplicações escaláveis. A comparação entre essas abordagens evidenciou que, embora o modelo geral identifique tendências, ele pode ocultar transições comportamentais sutis perceptíveis apenas em uma avaliação personalizada.

Um diferencial relevante da metodologia proposta é a utilização da área dos gráficos radar como métrica de esforço de condução, refletindo a intensidade de uso dos recursos veiculares. Essa métrica, combinada com a taxa de piscadas permitiu estabelecer correlações robustas entre maior esforço cognitivo e menor taxa de piscadas, especialmente em condutores classificados com estilo agressivo. Por outro lado, indivíduos com estilo consistente apresentaram áreas menores nos gráficos e maiores taxas de piscadas, indicando estado de alerta mais elevado e menor fadiga.

Esses achados reforçam a importância da análise conjunta de dados comportamentais e fisiológicos para a construção de sistemas inteligentes de assistência à condução. Sendo assim, é possível inferir o estado do motorista de forma precisa e não invasiva, a partir da combinação de parâmetros subjetivos do veículo com indicadores fisiológicos simples. Essa abordagem representa um avanço promissor para o desenvolvimento de soluções de segurança viária mais eficazes e centradas no usuário, especialmente em contextos de condução automatizada.

AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte e financiamento.

REFERENCES

- [1] N. Zhang, Z. Zhang, C. Ma, Z. Yang, S. Zhang, and J. Wu, "Fatigue driving state detection for tanker truck drivers based on multi-feature fusion," in *Fourth International Conference on Smart City Engineering and Public Transportation (SCEPT 2024)*, vol. 13160. SPIE, 2024, pp. 225–232.
- [2] N. Figalová, H.-J. Bieg, M. Schulz, J. Pichen, M. Baumann, L. L. Chuang, and O. Pollatos, "Fatigue and mental underload further pronounced in 13 conditionally automated driving: Results from an eeg experiment on a test track," in *Companion Proceedings of the 28th International Conference on Intelligent User Interfaces*, 2023, pp. 64–67.
- [3] D. Sirkin, N. Martelaro, M. Johns, and W. Ju, "Toward measurement of situation awareness in autonomous vehicles," in *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems*, 2017, pp. 405–415.
- [4] B. Bashiri and D. D. Mann, "Automation and the situation awareness of drivers in agricultural semi-autonomous vehicles," *Biosystems engineering*, vol. 124, pp. 8–15, 2014.
- [5] Z. Lu, R. Happee, C. D. Cabral, M. Kyriakidis, and J. C. De Winter, "Human factors of transitions in automated driving: A general framework and literature survey," *Transportation research part F: traffic psychology and behaviour*, vol. 43, pp. 183–198, 2016.
- [6] S. Wang, Z. Li, C. Zeng, and J. Hu, "Transitioning to multi-dimensional estimation of visual distraction and its safety effects under automated driving: a spatiotemporal and directional estimation approach," *Transportation research part C: emerging technologies*, vol. 153, p. 104212, 2023.
- [7] A. K. Sriranga, Q. Lu, and S. Birrell, "A systematic review of in-vehicle physiological indices and sensor technology for driver mental workload monitoring," *Sensors*, vol. 23, no. 4, p. 2214, 2023.
- [8] A. Arabiat and M. Altayeb, "Driving behavior analytics: an intelligent system based on machine learning and data mining techniques," *Bulletin of Electrical Engineering and Informatics*, vol. 14, no. 3, pp. 2055–2065, 2025.
- [9] M. E. Vaca-Recalde, M. Marcano, J. Sarabia, L. González, J. Pérez, and S. Díaz, "A fluid-hmi approach for haptic steering shared control for the hadrian project," in *HCI in Mobility, Transport, and Automotive Systems. Automated Driving and In-Vehicle Experience Design: Second International Conference, MobiTAS 2020, Held as Part of the 22nd HCI International Conference, HCII 2020, Copenhagen, Denmark, July 19–24, 2020, Proceedings, Part I* 22. Springer, 2020, pp. 417–428.
- [10] M. Sekadakis, M. Kallidoni, C. Katrakazas, S. Trösterer, C. Marx, P. Moertl, and G. Yannis, "Impact assessment of a novel human-machine interface prototype: A descriptive analysis from the hadrian project."
- [11] J. Yarlagadda and D. S. Pawar, "Heterogeneity in the driver behavior: An exploratory study using real-time driving data," *Journal of advanced transportation*, vol. 2022, no. 1, p. 4509071, 2022.
- [12] S. Chen, K. Cheng, J. Yang, X. Zang, Q. Luo, and J. Li, "Driving behavior risk measurement and cluster analysis driven by vehicle trajectory data," *Applied Sciences*, vol. 13, no. 9, p. 5675, 2023.
- [13] M. Silva, T. Flores, P. Andrade, J. Silva, I. Silva, and D. G. Costa, "An online unsupervised machine learning approach to detect driving related events," in *IECON 2022–48th Annual Conference of the IEEE Industrial Electronics Society*. IEEE, 2022, pp. 1–6.
- [14] A. Adavikottu and N. R. Velaga, "Analysis of factors influencing aggressive driver behavior and crash involvement," *Traffic injury prevention*, vol. 22, no. sup1, pp. S21–S26, 2021.
- [15] Hadrian, "Hadrian Project — Holistic Approach for Driver Role Integration and Automation Allocation for European Mobility Needs," <https://hadrianproject.eu/>, 2019, [Acessado em: 29-07-2024].
- [16] M. Silva, T. Flores, P. Andrade, J. Silva, I. Silva, and D. G. Costa, "An online unsupervised machine learning approach to detect driving related events," in *IECON 2022–48th Annual Conference of the IEEE Industrial Electronics Society*. IEEE, 2022, pp. 1–6.
- [17] W. Liu, B. Li, Y. Song *et al.*, "Driving fatigue detection based on optimized feature fusion of eeg and vehicle motion information," *Biomedical Signal Processing and Control*, vol. 88, p. 105395, 2024.
- [18] X. Zhang, J. Wu, Y. Sun, L. Yu, and Q. Xu, "Analyzing lane change behavior in congested conditions using real-time driving data," *Transportation Safety and Environment*, vol. 6, no. 3, p. tdad039, 2024.
- [19] Z. Zhang, J. Li, M. Liu, and W. Yan, "A review of fatigue driving behavior recognition methods based on vehicle and physiological data," *Journal of Intelligent & Fuzzy Systems*, vol. 46, no. 1, pp. 905–921, 2024.
- [20] M. M. R. Ahmed, R. H. Seraj, and S. M. S. Islam, "The k-means algorithm: A comprehensive survey and performance evaluation," *Electronics*, vol. 9, no. 8, p. 1295, 2020.
- [21] H. Huang, Y. Wang, C. Rudin, and E. P. Browne, "Towards a comprehensive evaluation of dimension reduction methods for transcriptomic data visualization," *Communications biology*, vol. 5, no. 1, p. 719, 2022.
- [22] M. B. D. d. Silva, "Uma metodologia orientada a fluxo de dados para modelagem do comportamento de motoristas," 2022.