



Estimação de perfis de condução

Mestrado em Engenharia Automóvel

Tomás Martins Rei

Leiria, abril de 2026



Estimação de perfis de condução

Mestrado em Engenharia Automóvel

Tomás Martins Rei

Projeto de mestrado realizado sob a orientação do Professor Doutor Lino Miguel Moreira Ferreira, do Professor Doutor Nuno Manuel Lucas Vieira Lopes e do Professor Sérgio Manuel da Silva.

Leiria, abril de 2026

Originalidade e direitos de autor

A presente dissertação é original, elaborada unicamente para este fim, tendo sido devidamente citados todos os autores cujos estudos e publicações contribuíram para a elaborar.

Reproduções parciais deste documento serão autorizadas na condição de que seja mencionado o Autor e feita referência ao ciclo de estudos no âmbito do qual a mesma foi realizada, a saber, Curso de Mestrado em Engenharia Automóvel, no ano letivo 2025/2026, da Escola Superior de Tecnologia e Gestão do Instituto Politécnico de Leiria, Portugal, e, bem assim, à data das provas públicas que visaram a avaliação destes trabalhos.

Dedicatória

A todos os que caminharam comigo, nos dias fáceis e nos difíceis. Obrigado por nunca me deixarem desistir.

Agradecimentos

Ao concluir esta etapa tão significativa da minha vida académica, sinto a necessidade de expressar a minha sincera gratidão a todos aqueles que, de diferentes formas, contribuíram para a realização deste trabalho. O projeto de mestrado em Engenharia Automóvel que apresento neste relatório, representa não apenas o culminar de um percurso, mas também o reflexo do apoio, dedicação e incentivo de muitas pessoas que me acompanharam ao longo deste caminho.

Gostaria de começar por agradecer profundamente aos meus orientadores, **Professor Lino Ferreira, Professor Nuno Vieira Lopes e Professor Sérgio Silva**, pela orientação incansável, pela disponibilidade permanente e pelo rigor científico que sempre demonstraram. A vossa orientação e apoio foi determinante para o meu crescimento académico e pessoal, e sou-vos verdadeiramente grato por cada esclarecimento, sugestão e desafio que me permitiram evoluir ao longo deste projeto.

À **Escola Superior de Tecnologia e Gestão (ESTG) do Instituto Politécnico de Leiria**, expresso também o meu reconhecimento por todo o conhecimento transmitido ao longo dos anos e por proporcionar um ambiente académico que me permitiu desenvolver competências fundamentais para a minha formação na minha Licenciatura e no meu Mestrado em Engenharia Automóvel.

Aos meus pais, **Manuel Fernando Rei Tomás e Maria do Rosário Martins Pedro**, deixo um agradecimento especial pelo amor incondicional, pela paciência e pelo apoio constante. Foram sempre a minha base, o meu porto seguro e a minha maior motivação para continuar a esforçar-me e a procurar ser melhor todos os dias.

À minha namorada, **Maria João Carreira**, agradeço por todo o carinho, compreensão e apoio nos momentos mais exigentes deste percurso. A sua presença constante e incentivo foram fundamentais para que conseguisse ultrapassar os desafios que surgiram ao longo desta caminhada.

Quero ainda deixar um agradecimento especial ao meu colega e amigo **Celso Luz**, pela amizade, companheirismo e apoio constante ao longo deste percurso. A sua presença, disponibilidade e boa disposição tornaram este caminho mais simples e motivador.

A toda a minha família e amigos, que sempre acreditaram em mim e me acompanharam ao longo deste trajeto, deixo igualmente o meu sincero agradecimento. Cada palavra de apoio, cada gesto de incentivo e cada momento de compreensão contribuíram para que esta etapa fosse possível.

Por fim, gostaria ainda de expressar um agradecimento muito especial a todos os proprietários que gentilmente cederam os seus veículos pessoais para a realização deste projeto. A vossa disponibilidade, confiança e colaboração foram absolutamente essenciais para a recolha de dados e para o desenvolvimento experimental deste projeto. Sem o vosso contributo, este trabalho não teria alcançado a profundidade e a qualidade necessária. A cada um de vós, deixo o meu sincero reconhecimento e gratidão.

O meu muito obrigado a cada um de vocês. Sem o vosso apoio, este percurso não teria sido possível.

Tomás Martins Rei

Resumo

Este relatório de projeto de mestrado detalha o desenvolvimento de um sistema capaz de adquirir e registrar dados de um veículo automóvel através do sistema de diagnóstico OBD-II, para o seu processamento, em ambiente externo, originando a estimação dos perfis de condução categorizados como leve, moderado e agressivo.

O sistema de aquisição de dados é baseado num microcontrolador que comunica com o sistema OBD-II através de um *transceiver* CAN, permitindo a aquisição de velocidade do veículo e da velocidade de rotação do motor, e o subsequente registo em cartão de memória.

Foram analisadas várias abordagens de classificação de dados para a estimação dos perfis de condução envolvendo diversas combinações de variáveis, mas a que originou melhores resultados foi a baseada na combinação de limiares de aceleração e de velocidade de rotação do motor.

A validação foi realizada utilizando dois percursos de referência, calculando um erro, obtido pela soma das médias dos erros absolutos originados por cada abordagem relativamente aos dois percursos de referência.

Os testes experimentais confirmaram a capacidade do sistema em estimar de forma coerente o comportamento do condutor em contexto real. Os resultados da estimação foram apresentados sob a forma de histogramas que quantificam as ocorrências dos perfis leve, moderado e agressivo no final do percurso, fornecendo uma visão global do comportamento do condutor. Além disso, foram mostradas as evoluções temporal e espacial desses perfis, permitindo uma análise mais detalhada.

De forma geral, o trabalho desenvolvido mostrou-se funcional, fiável e adequado à estimação de perfis de condução, constituindo uma base sólida para futuras melhorias, nomeadamente a integração de dados contextuais, a adaptação dinâmica dos limites e a expansão para outros tipos de veículos que não apenas o veículo diesel usado neste trabalho.

Palavras-chave: perfis de condução, OBD-II, aquisição e registo de dados, aceleração, velocidade de rotação do motor.

Abstract

This master's thesis details the development of a system capable of acquiring and recording data from a motor vehicle via the OBD-II diagnostic system, to be processed in an external environment, thereby enabling the estimation of driving profiles categorized as smooth, moderate and aggressive.

The data acquisition system is based on a microcontroller that communicates with the OBD-II system via a CAN transceiver, enabling the acquisition of vehicle speed and engine speed, and their subsequent recording onto a memory card.

Several data classification approaches were analyzed for estimating driving profiles involving different combinations of variables, but the one that yielded the best results was based on a combination of acceleration and engine speed thresholds.

Validation was carried out using two reference routes, calculating an error obtained by summing the averages of the absolute errors produced by each approach relative to the two reference routes.

The experimental tests confirmed the system's ability to consistently estimate driver behavior in a real-world context. The estimation results were presented in the form of histograms quantifying the occurrences of smooth, moderate and aggressive profiles at the end of the route, providing an overall view of the driver's behavior. Furthermore, the temporal and spatial evolution of these profiles was shown.

Overall, the work carried out proved to be functional, reliable and suitable for estimating driving profiles, providing a solid foundation for future improvements, particularly the integration of contextual data, the dynamic adaptation of thresholds, and the extension to other types of vehicles beyond the diesel vehicle used in this study.

Keywords: driving profiles, OBD-II, data acquisition and recording, acceleration, engine speed.

Índice

Originalidade e direitos de autor	iii
Dedicatória	v
Agradecimentos	vii
Resumo	ix
Abstract	xi
Índice	xiii
Lista de figuras	xv
Lista de tabelas	xvii
Lista de siglas e acrónimos.....	xix
1. Introdução	1
1.1. Enquadramento e motivação	1
1.2. Objetivos.....	2
1.3. Estrutura do relatório	4
2. Revisão bibliográfica	5
2.1. Estimação envolvendo dados do sistema de diagnóstico OBD-II.....	5
2.2. Estimação envolvendo dados adquiridos com sensores externos.....	9
2.3. Estimação envolvendo dados do sistema OBD II e adquiridos por sensores externos.....	12
2.4. Padrões de condução e análise temporal	14
2.5. Análise comparativa	15
3. Sistema de aquisição e registo de dados	21
3.1. Desenvolvimento do <i>hardware</i>	21
3.1.1. Microcontrolador	22
3.1.2. Módulo <i>transceiver</i> CAN	24
3.1.3. Módulo de cartões de memória	25
3.1.4. Sistema desenvolvido	25

3.2.	Desenvolvimento do <i>firmware</i>	29
4.	Desenvolvimento do método de estimação	33
4.1.	Leitura e preparação inicial dos dados	34
4.2.	Estimação baseada na aceleração	35
4.3.	Estimação baseada no <i>jerk</i>	40
4.4.	Estimação baseada em aceleração e <i>jerk</i>	41
4.5.	Estimação baseada na velocidade de rotação do motor e <i>jerk</i>	42
4.6.	Estimação baseada na velocidade de rotação do motor e aceleração.....	45
4.7.	Considerações finais.....	47
5.	Aplicação do método e apresentação de resultados	49
6.	Conclusões e trabalho futuro	53
	Referências bibliográficas.....	55
	Anexo.....	59

Lista de figuras

Figura 1-1 – Diagrama de blocos do trabalho a desenvolver.....	3
Figura 2-1 – Sistema de aquisição de dados desenvolvido por [17].....	10
Figura 3-1 – Diagrama de blocos da arquitetura geral do sistema.....	21
Figura 3-2 - Identificação dos terminais da placa ESP32 ESP-WROOM-32.....	23
Figura 3-3 – Adaptador de isqueiro.....	23
Figura 3-4 - Módulo <i>transceiver</i> MCP2551.....	24
Figura 3-5 – Ficha OBD-II: a) aspeto exterior e b) identificação dos terminais.....	25
Figura 3-6 - Cartão microSD de 16GB e respetivo módulo.....	25
Figura 3-7 - Diagrama de blocos do sistema de aquisição e registo de dados.....	26
Figura 3-8 - Esquema elétrico do sistema de aquisição e registo de dados.....	27
Figura 3-9 - Primeiro protótipo do sistema de aquisição e registo de dados.....	27
Figura 3-10 – Vista inferior da PCI desenvolvida.....	28
Figura 3-11 – Desenho 3D da caixa: a) caixa e b) tampa.....	28
Figura 3-12 – Protótipo final do sistema de aquisição e registo de dados: a) vista interior e b) vista exterior.....	29
Figura 3-13 - Fluxograma do <i>firmware</i> desenvolvido.....	31
Figura 4-1 – Histogramas dos dois percursos de referência: a) percurso 1 e b) percurso 2.....	34
Figura 4-2 - Volkswagen Golf Mark VII 2.0 TDI GTD (2013).....	34
Figura 4-3 – Histogramas correspondentes ao percurso de referência 1; a) Limiares de aceleração dos artigos [20] e [11]; b) limiares de aceleração do artigo [24]; c) limiares de aceleração propostos para este trabalho.....	37
Figura 4-4 – Histogramas correspondentes ao percurso de referência 2; a) limiares de aceleração dos artigos [20] e [11]; b) limiares de aceleração do artigo [24]; c) limiares de aceleração propostos para este trabalho.....	38
Figura 4-5 - Histogramas correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2... ..	40
Figura 4-6 - Histogramas correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2... ..	42
Figura 4-7 - Gráfico VRM- <i>jerk</i> correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2.....	43
Figura 4-8 - Histogramas correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2... ..	44
Figura 4-9 - Gráfico VRM-aceleração correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2.....	46
Figura 4-10 - Histogramas correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2.....	46

Figura 5-1 - Distribuição dos perfis de condução no percurso entre Alcobaça e Caldas da Rainha	50
Figura 5-2 – Evolução temporal do perfil de condução no percurso entre Alcobaça e Caldas da Rainha	50
Figura 5-3 - Mapa com os perfis de condução ao longo do percurso entre Alcobaça e Caldas da Rainha	50
Figura 5-4 - Distribuição dos perfis de condução no percurso em Alcobaça	51
Figura 5-5 - Evolução temporal do perfil de condução no percurso em Alcobaça	52
Figura 5-6 - Mapa com os perfis de condução ao longo do percurso em Alcobaça	52

Lista de tabelas

Tabela 1 - Comparação das abordagens existentes na literatura.....	17
Tabela 2 - Limiares de aceleração para a estimação do perfil de condução segundo [20] e [11].....	36
Tabela 3 - Limiares de aceleração adaptados para a estimação do perfil de condução	36
Tabela 4 - Limiares de aceleração para estimação do perfil de condução segundo [24]	36
Tabela 5 - Limiares de aceleração propostos para a estimação do perfil de condução.....	37
Tabela 6 - Erros obtidos na estimação usando a aceleração	39
Tabela 7 - Valores de <i>jerk</i> para classificação do perfil de condução segundo [34].....	40
Tabela 8 - Erros obtidos na estimação usando o <i>jerk</i>	41
Tabela 9 - Erros obtidos na estimação usando a aceleração e <i>jerk</i>	42
Tabela 10 - Limiares definidos para a velocidade de rotação do motor	43
Tabela 11 - Erros obtidos na estimação usando a velocidade de rotação do motor e <i>jerk</i>	44
Tabela 12 - Erros obtidos na estimação usando a velocidade de rotação do motor e a aceleração.....	47
Tabela 13 - Média do erro absoluto dos resultados dos percursos de referência	47
Tabela 14 - Erro total das abordagens	48

Lista de siglas e acrónimos

ADAS	Advanced Driver Assistance Systems
ANN	Artificial Neural Network
API	Application Programming Interface
CAN	Controller Area Network
CO ₂	Dióxido de carbono
CSV	Comma-Separated Values
DTW	Dynamic Time Warping
DBSCAN	Density-Based Spatial Clustering of Applications with Noise
ECU	Engine Control Unit
ELM	Extreme Learning Machine
ESTG	Escola Superior de Tecnologia e Gestão
GeoSTMUM	Geospatial Spatio-Temporal Urban Mobility Model
GMM	Gaussian Mixture Model
GPS	Global Positioning System
GRU	Gated Recurrent Unit
IVDR	In-Vehicle Data Recorder
LSB	Least Significant Byte
LSTM	Long Short-Term Memory
MAF	Mass Air Flow
MSB	Most Significant Byte
NA	Não Aplicável
NO _x	Óxidos de azoto (NO + NO ₂)
OBD	On-Board Diagnostics
PCA	Principal Component Analysis
PCI	Placa de Circuito Impresso
PID	Parameter ID
KNN	K-Nearest Neighbors
SAE	Society of Automotive Engineers
SPI	Serial Peripheral Interface
SUMO	Simulation of Urban Mobility

SVM	Support Vector Machine
TAI	Trajectory Aggressivity Indicator
VRM	Velocidade de Rotação do Motor

1. Introdução

Este capítulo introduz o enquadramento e a motivação subjacentes ao projeto de mestrado em Engenharia Automóvel, apresenta os seus objetivos e descreve a estrutura deste relatório.

1.1. Enquadramento e motivação

Ao longo das últimas décadas, a sociedade tem vindo a reconhecer de forma crescente o impacto ambiental e energético associado ao setor dos veículos e dos transportes. Durante muitos anos, a poluição proveniente dos veículos e a exploração intensiva de combustíveis fósseis não eram encaradas como problemas urgentes. Os fabricantes de automóveis operavam num contexto praticamente isento de normas ambientais, sem limites de emissões definidos, e o consumo de combustível não constituía uma preocupação central para a maioria dos condutores. A questão ambiental, hoje amplamente discutida, tinha então um peso reduzido nas decisões de fabrico e de utilização dos veículos.

Com o agravamento dos problemas ambientais e o aumento significativo da frota automóvel mundial, tornou-se evidente a necessidade de regulamentar as emissões de poluentes. Surgiram assim normas antipoluição cada vez mais exigentes, como as normas europeias Euro 1 a Euro 6, que obrigaram os fabricantes a reduzir drasticamente os níveis de emissões e a melhorar a eficiência energética dos motores. Paralelamente, a subida contínua do preço dos combustíveis reforçou a necessidade de desenvolver veículos mais económicos, incentivando a introdução de sistemas eletrónicos avançados de controlo do motor e de gestão de energia. Este conjunto de fatores conduziu a uma transformação profunda na indústria automóvel, que passou a privilegiar soluções mais eficientes, sustentáveis e tecnologicamente evoluídas.

Neste contexto, o estilo de condução assume um papel determinante. A literatura demonstra que comportamentos de condução agressivos, como acelerações bruscas, velocidades excessivas ou travagens intensas, aumentam significativamente o consumo de combustível, o desgaste mecânico e as emissões de poluentes. Por outro lado, uma condução moderada e eficiente contribui para reduzir o impacto ambiental, prolongar a vida útil dos componentes do veículo e diminuir os custos associados à utilização diária. Assim, a estimação e a análise

de perfis de condução tornam-se ferramentas essenciais para promover hábitos de condução mais sustentáveis e economicamente vantajosos.

Para além dos impactos ambientais e económicos, a adoção de uma condução segura desempenha um papel fundamental na redução do risco de acidentes rodoviários. Estudos na área da segurança rodoviária demonstram que comportamentos como o respeito pelos limites de velocidade, a manutenção de distâncias de segurança, a antecipação de situações de risco e a ausência de manobras bruscas contribuem significativamente para diminuir a probabilidade de colisões. Uma condução mais estável e previsível permite ao condutor reagir de forma mais eficaz a imprevistos, reduzindo a gravidade dos acidentes e aumentando a segurança de todos os utilizadores da via. Assim, a promoção de estilos de condução seguros não só melhora a eficiência e o conforto, como constitui um elemento essencial para a prevenção da sinistralidade rodoviária.

O projeto relatado neste documento surge precisamente desta necessidade: desenvolver um sistema capaz de estimar perfis de condução de condutores de veículos automóveis. A identificação destes perfis permite sensibilizar os condutores para práticas mais eficientes, contribuindo para a redução do consumo de combustível, para a diminuição das emissões e para um menor desgaste dos veículos. Além disso, a informação obtida pode ser particularmente útil para gestores de frotas, que procuram otimizar custos operacionais, melhorar a segurança e monitorizar o comportamento dos seus condutores.

A pertinência deste projeto reforça-se ainda pelo contexto atual, marcado pela transição energética, pela crescente digitalização dos veículos e pela valorização de soluções inteligentes de mobilidade. A estimação de perfis de condução, suportada por dados reais e técnicas de processamento, constitui assim uma ferramenta relevante tanto para utilizadores particulares como para entidades empresariais, contribuindo para uma mobilidade mais eficiente, segura, sustentável e alinhada com as exigências tecnológicas e ambientais da atualidade.

1.2.Objetivos

Para este projeto era pretendido o desenvolvimento de um sistema para adquirir e registar dados relacionados com a condução de veículos automóveis para que, através do seu processamento, se conseguisse como objetivo global estimar o perfil de condução dos condutores, classificando-os em três categorias, leve, moderado e agressivo.

A primeira etapa do projeto previa o desenvolvimento de um módulo de aquisição e registo de dados para interligar ao sistema On-Board Diagnostics (OBD-II), com o requisito de ser compatível com diferentes modelos de veículos. O propósito específico era o de se extraírem continuamente vários parâmetros da Engine Control Unit (ECU), como a velocidade do automóvel, a Velocidade de Rotação do Motor (VRM) e o *timestamp* de cada amostra. Para viabilizar a comunicação a nível físico, o módulo deveria integrar um *transceiver* de alta velocidade para a Controller Area Network (CAN), responsável por fazer a *interface* eletrónica entre um adequado microcontrolador e as linhas diferenciais da CAN disponíveis no conector OBD-II. Para o registo de dados, era pressuposto incorporar um módulo de leitura e escrita de cartões de memória microSD.

Quanto ao processamento propriamente dos dados registados em cartão microSD, era pressuposto utilizar-se o Matlab para esse propósito. Além disso, era também pressuposto usar-se dados de Global Positioning System (GPS) adquiridos com um *smartphone*, para se poder estabelecer a relação entre os perfis estimados e os respetivos percursos efetuados. Em resumo, era pretendido alcançar-se um algoritmo simples de estimação de perfis de condução, mas com rigor técnico e validade prática.

A Figura 1-1 esquematiza o diagrama de blocos do trabalho que se pretendia desenvolver.




Figura 1-1 – Diagrama de blocos do trabalho a desenvolver

1.3.Estrutura do relatório

Este relatório está estruturado em seis capítulos, sendo que este introdutório é o primeiro.

No segundo capítulo é apresentada uma revisão bibliográfica baseada em diversas referências, com o objetivo de obter uma percepção clara do estado da arte na estimação de perfis de condução. Nesta revisão analisam-se as formas como diferentes autores definem e caracterizam os perfis de condução, as variáveis utilizadas para esse fim e os métodos de processamento de dados aplicados. São igualmente descritos alguns dispositivos e sensores frequentemente utilizados neste tipo de sistemas, permitindo enquadrar tecnicamente o desenvolvimento do projeto.

No terceiro capítulo é descrito o desenvolvimento do sistema proposto para a aquisição e registo de dados, dividido em duas partes principais: *hardware* e *firmware*. No subcapítulo dedicado ao *hardware* apresentam-se os dispositivos selecionados, as suas características e a forma como são interligados. No subcapítulo referente ao *firmware* é explicada a lógica de funcionamento do sistema, incluindo as formas de comunicação, o pré-processamento dos sinais e o registo em cartão de memória.

O quarto capítulo é dedicado à análise comparativa das abordagens para a estimação de perfis de condução, onde são estudadas e comparadas diferentes combinações de limiares e variáveis, para dois percursos de referência.

No quinto capítulo apresentam-se os resultados de estimação de perfis de condução em contexto real. Para tal, foram efetuados dois percursos experimentais, adquirindo-se e registando dados de aceleração e velocidade de rotação do motor cuja classificação foi representada sob a forma de histogramas e evoluções temporais e espaciais dos perfis.

Por fim, no sexto capítulo são apresentadas as conclusões sobre o trabalho desenvolvido, bem como sugestões de trabalho futuro.

Em anexo é apresentado um guia de utilização do sistema de aquisição e registo de dados desenvolvido.

2. Revisão bibliográfica

A análise do comportamento de condução dos condutores de veículos tem vindo a ganhar uma crescente relevância na investigação automóvel, impulsionada pela necessidade de melhorar a segurança rodoviária, reduzir consumos e emissões, e compreender de forma mais profunda a interação entre o condutor e o veículo. A evolução dos sistemas de aquisição de dados, desde os acessíveis através do sistema OBD-II até aos sensores de smartphones e telemática embarcada, tem permitido o desenvolvimento de metodologias cada vez mais sofisticadas para caracterizar estilos de condução, identificar padrões temporais e detetar comportamentos de risco. Esta revisão bibliográfica está organizada de modo a permitir compreender e relacionar, não apenas as metodologias utilizadas, mas também as variáveis consideradas, as várias formas com que são adquiridas, os perfis de condução identificados e as métricas usadas nos diversos trabalhos de investigação analisados.

2.1. Estimação envolvendo dados do sistema de diagnóstico OBD-II

Os trabalhos de estimação de perfis de condução baseados em dados adquiridos através do sistema de diagnóstico OBD-II constituem uma das abordagens mais consolidadas na literatura, devido à fiabilidade dos dados provenientes da ECU e à normalização dos Parameter ID (PIDs) definidos pela norma SAE J1979. Estes dados incluem várias variáveis, tais como, velocidade do veículo, VRM, posição do pedal do acelerador, carga do motor, valor do Mass Air Flow (MAF), temperatura do ar, consumo estimado e pressão do coletor. A principal vantagem desta abordagem reside no facto de estas variáveis refletirem diretamente o comportamento do condutor sobre o motor e a dinâmica longitudinal do veículo.

O trabalho apresentado em [1] é frequentemente citado como um dos primeiros a demonstrar que os dados adquiridos pelo sistema de diagnóstico OBD-II podem ser utilizados para identificar, com elevada precisão, padrões de condução. Os autores adquiriram dados em contexto real, utilizando um sistema de aquisição ligado ao sistema OBD-II do veículo, e aplicaram algoritmos de *boosting* (AdaBoost) para classificar eventos de aceleração, velocidade e carga do motor. A análise revelou que variáveis como a velocidade, aceleração longitudinal (derivada da velocidade) e carga do motor são altamente discriminativas para distinguir entre condução agressiva e moderada. Este estudo abriu caminho para a utilização

do sistema de diagnóstico OBD-II como fonte primária de dados, para a determinação de perfis de condução, classificando-os assim em dois níveis, sendo eles agressivo e moderado. O Adaptive Boosting (AdaBoost) [2] é um algoritmo de *ensemble learning* supervisionado que combina vários classificadores fracos para formar um classificador forte. Cada iteração dá mais peso aos exemplos mal classificados, melhorando progressivamente o desempenho. É eficaz para distinguir entre estilos de condução binários, como “normal” vs. “agressivo”, mas depende de dados rotulados e tende a sobreajustar em *datasets* pequenos.

A investigação descrita em [3], propõe uma arquitetura de classificação de perfis de condução baseada em dados recolhidos através do sistema OBD-II e dados registados a bordo, In-Vehicle Data Recorder (IVDR). Os autores definem um conjunto alargado de atributos do condutor, organizados em sinais primários (diretamente influenciados por ações como a aceleração, travagem, direção ou mudança de velocidade), secundários (variáveis derivadas tais como a temperatura do motor e consumo) e terciários (ajustes de conforto, iluminação ou climatização). O estudo introduz ainda a distinção entre características estáticas e dinâmicas, bem como a influência de diferentes cenários de condução, tais como, tráfego, emergência, noite e fim de semana.

O estudo apresentado em [4], utiliza técnicas de *clustering*, nomeadamente K-Means, para realizar agrupamentos com base em métricas como aceleração longitudinal, variação de velocidade e intensidade de travagem. O estudo destaca a importância de métricas derivadas, como o desvio padrão da aceleração, que captam a variabilidade do comportamento ao longo do tempo. A utilização do *Rand Index* (métrica estatística usada para avaliar a qualidade de um *clustering*), para validar os *clusters* demonstra uma preocupação metodológica com a robustez dos resultados. O K-Means [5] é um algoritmo de *clustering* não supervisionado que agrupa dados em *k clusters*, minimizando a distância entre cada ponto e o centro do *cluster*. O método assume que os dados podem ser divididos em grupos com características semelhantes e é amplamente utilizado em estimação de perfis de condução para identificar padrões de aceleração, velocidade ou comportamento geral do condutor.

Por sua vez, os autores de [6] utilizam dados provenientes do sistema OBD-II para classificar condutores em três perfis, sendo eles, agressivo, moderado e leve, recorrendo a variáveis típicas, como velocidade e carga do motor, para alimentar os algoritmos como K-Nearest Neighbors (KNN) e Extreme Learning Machine (ELM). Os autores mostram que o KNN atinge cerca de 99% de precisão, enquanto o ELM, embora ligeiramente menos preciso,

apresenta vantagens em termos de velocidade computacional. Este estudo é particularmente relevante por demonstrar que modelos simples podem ser altamente eficazes quando aplicados a variáveis OBD-II. O KNN [7] é um método supervisionado que classifica um novo ponto com base nos K vizinhos mais próximos no espaço das características. É simples e intuitivo, mas sensível à escala dos dados e ao ruído. Em perfis de condução, é usado para comparar padrões de aceleração, travagem e velocidade entre condutores. O ELM [8] é uma rede neuronal de camada única com pesos aleatórios na camada escondida e solução analítica na camada de saída. É extremamente rápida e adequada para classificação em tempo real. No contexto de estimação de perfis de condução, é utilizado de forma relevante pois permite distinguir perfis com base em múltiplas variáveis disponibilizadas pelo sistema OBD-II.

Na investigação descrita em [9] são utilizadas variáveis como velocidade do veículo, VRM, posição do pedal do acelerador e carga do motor para detetar momentos de condução agressiva, nomeadamente acelerações bruscas, travagens bruscas e curvas agressivas. Os autores implementam um módulo de aquisição em tempo real ligado ao sistema OBD-II e aplicam regras heurísticas para classificar o comportamento do condutor em normal, moderado e agressivo. Embora metodologicamente mais simples do que comparativamente a trabalhos que usam *machine learning*, este trabalho reforça a utilidade dos PIDs públicos para identificar padrões de risco e demonstra a viabilidade de sistemas de baixo custo para monitorização contínua do comportamento de condução.

As regras heurísticas consistem em definir limites para classificar comportamentos (por exemplo, aceleração $> 2 \text{ m/s}^2$ = agressivo). Embora alguns estudos utilizem este método como abordagem principal, vários trabalhos combinam regras heurísticas com técnicas mais avançadas, utilizando-as sobretudo para detetar eventos específicos ou para gerar métricas que servem de entrada para algoritmos de classificação.

O trabalho apresentado em [10], monitoriza variáveis como a velocidade do veículo, nível de bateria, distância percorrida e autonomia estimada, avaliando seis condutores num percurso controlado de 200 km. Os resultados mostram diferenças significativas no consumo energético entre condutores, mesmo sob condições idênticas de tráfego e ambiente, evidenciando que o estilo de condução tem impacto direto na eficiência e na autonomia. Este trabalho reforça a importância das métricas que utilizam dados provenientes do sistema OBD-II para caracterizar perfis de condução, demonstrando que comportamentos mais

suaves e velocidades médias mais estáveis estão associados a menores consumos energéticos em veículos elétricos.

Finalmente, o estudo apresentado em [11] demonstra que é possível identificar condutores individualmente (*driver ID*) com base em PIDs públicos, tais como: velocidade do veículo, VRM, posição do pedal do acelerador, carga do motor e consumo instantâneo. Para esse fim, os autores aplicam vários modelos supervisionados, Support Vector Machine (SVM), Decision Trees, Random Forest e Logistic Regression, atingindo cerca de 79% de precisão. Este resultado é importante porque evidencia que o estilo de condução é suficientemente distintivo para permitir a identificação de indivíduos, mesmo com um conjunto limitado de variáveis.

O SVM [12] é um método de *machine learning* supervisionado que determina o hiperplano capaz de otimizar a separação entre classes no espaço de características. Este algoritmo destaca-se pela sua robustez e eficácia em conjuntos de dados (*datasets*) que apresentem margens de separação claras entre perfis. No contexto automóvel, a sua aplicação foca-se na distinção de perfis de condução, recorrendo a parâmetros dinâmicos como a aceleração, a velocidade do veículo, a VRM e o consumo de combustível.

As *Decision Trees* [13] consistem em modelos de classificação que segmentam os dados em ramos através de condições lógicas sucessivas, gerando regras explícitas e de fácil interpretação. Este método identifica, de forma automática, os limiares críticos em variáveis como a aceleração, a velocidade do veículo ou a VRM, permitindo discriminar com precisão os diferentes perfis de condução.

A Random Forest [14] consiste num método de classificação baseado na combinação de múltiplas árvores de decisão, criadas a partir de subconjuntos aleatórios dos dados e das variáveis. Ao agregar as previsões de várias árvores, o modelo reduz o risco de sobreajuste e aumenta a precisão da classificação. Esta abordagem é eficaz para lidar com padrões de condução complexos, embora perca alguma interpretabilidade devido ao grande número de árvores envolvidas.

Logistic Regression [15] é um método de classificação supervisionada que modela a probabilidade de um dado pertencer a uma classe, utilizando uma função logística para separar categorias. O modelo identifica relações lineares entre variáveis, permitindo distinguir comportamentos de condução com base em métricas como aceleração, velocidade

ou VRM. É simples, eficiente e adequado para problemas binários ou multiclass, embora seja limitado quando as fronteiras entre perfis não são aproximadamente lineares.

Em síntese, os estudos baseados em dados adquiridos através do sistema OBD-II destacam-se pela objetividade das variáveis utilizadas, pela facilidade de aquisição dos dados e pela elevada precisão dos modelos de classificação. No entanto, apresentam limitações ao nível da frequência de aquisição de dados e da ausência de informação do comportamento lateral do veículo, o que motiva o recurso a sensores externos.

2.2. Estimação envolvendo dados adquiridos com sensores externos

A utilização de *smartphones* como fonte de aquisição e registo de dados para a análise do comportamento de condução tem vindo a ganhar destaque devido a ser um dispositivo muito vulgar nos dias de hoje, muitos deles de baixo custo, mas com a capacidade de adquirir e registar, com elevadas taxas de aquisição, utilizando sensores como acelerómetro, giroscópio e GPS. Estes sensores permitem captar a dinâmica do veículo em três dimensões, ao nível da translação e da rotação, e também a geolocalização do veículo; o que não se consegue com o sistema OBD-II.

O trabalho desenvolvido em [16] é um dos mais completos nesta área, utilizando sensores de um *smartphone* para detetar eventos agressivos como acelerações bruscas, travagens bruscas e curvas intensas. Os autores aplicam modelos supervisionados como Artificial Neural Networks (ANN), SVM e Random Forest, demonstrando que a análise de sinais de velocidade e aceleração do veículo, e VRM, permite identificar eventos de risco com elevada precisão. Este trabalho destaca a importância da frequência de amostragem e da filtragem dos sinais, uma vez que os sensores incorporados em *smartphones* são suscetíveis a ruído e vibrações. As ANN [15] são modelos de aprendizagem supervisionada inspirados no funcionamento do cérebro humano, compostos por camadas de neurónios artificiais que aprendem padrões complexos a partir dos dados de treino. Ao ajustar os pesos entre neurónios durante o treino, conseguem identificar relações não lineares entre variáveis, tornando-as adequadas para detetar comportamentos de condução mais complexos. Apesar da sua elevada capacidade de modelação, perdem interpretabilidade e exigem conjuntos de dados maiores para um desempenho consistente.

Por outro lado, o estudo apresentado em [17] compara medições de velocidade obtidas do sistema OBD-II, GPS dedicado e aplicações de *smartphone*, concluindo que os valores

provenientes do sistema OBD-II e das aplicações móveis são bastante próximos, enquanto o GPS dedicado apresenta maior variabilidade. Este estudo valida o uso de *smartphones* como fonte fiável de aquisição de dados para a estimação de perfis de condução, sobretudo quando combinados com dados provenientes do sistema OBD-II. O sistema de aquisição de dados desenvolvido neste estudo encontra-se ilustrado na Figura 2-1.



Figura 2-1 – Sistema de aquisição de dados desenvolvido por [17]

No domínio de veículos de duas rodas, os autores de [18] utilizam dados provenientes de sensores de um *smartphone* para definir limiares de aceleração e travagem em motociclos, classificando o comportamento em normal, agressivo e perigoso. O estudo destaca a importância de métricas como aceleração longitudinal e desaceleração extrema, que são particularmente relevantes em contextos de maior instabilidade dinâmica dos motociclos.

A investigação descrita em [19], em que os perfis de condução são determinados com base em dados adquiridos exclusivamente por smartphones, com foco na relação entre aceleração, estilo de condução e impacto ambiental. Os autores aplicam o K-Means para identificar três perfis distintos, sendo eles, económico, normal e agressivo, caracterizados com base em métricas de aceleração, desaceleração e frequência de eventos bruscos. Posteriormente,

avaliam o impacto destes perfis no tráfego e nas emissões através de simulação microscópica com o Simulador de Mobilidade Urbana (SUMO), demonstrando que a condução suave reduz significativamente o dióxido de carbono (CO₂), óxidos de azoto (NO_x) e consumo de combustível, além de melhorar o fluxo de tráfego. Este estudo reforça a importância dos sensores existentes em *smartphone* como fonte viável para caracterizar estilos de condução e avaliar o impacto sistêmico de comportamentos agressivos.

Em [20], é apresentado um método particularmente relevante no contexto das fontes baseadas em *smartphone*, demonstrando que é possível identificar comportamentos agressivos recorrendo apenas a dados adquiridos via GPS, desde que este seja enriquecido com informação contextual. O *pipeline* proposto inclui quatro fases, sendo elas, aquisição, pré processamento, enriquecimento semântico e avaliação, permitindo transformar trajetórias em segmentos de 1 km com contexto detalhado de limites de velocidade, condições meteorológicas e proximidade a zonas sensíveis. O pré processamento utiliza Density-Based Spatial Clustering of Applications with Noise (DBSCAN) para limpeza de ruído e um classificador J48 para distinguir transporte motorizado de não motorizado, assegurando que apenas deslocações relevantes são analisadas. O enriquecimento semântico é um dos pontos fortes do método: integra limites de velocidade obtidos via Application Programming Interface (API), ajusta esses limites com base no tipo de via e aplica reduções dinâmicas consoante o estado do tempo, modelando o impacto da chuva na aderência e na aceleração segura. A fase final combina velocidade e aceleração em múltiplas categorias de agressividade para produzir um Trajectory Aggressivity Indicator (TAI) entre 0 e 100. Os resultados mostram que o enriquecimento contextual altera significativamente a classificação, trajetórias consideradas seguras em piso seco tornam-se moderadamente agressivas em condições de chuva, evidenciando a importância de incorporar contexto externo. Este estudo reforça que, mesmo sem acesso ao sistema OBD-II ou barramento CAN, dados provenientes de *smartphone* permitem construir indicadores fiáveis de agressividade, tornando-se uma alternativa acessível e ubíqua para caracterizar perfis de condução em cenários reais.

O DBSCAN [21] é um algoritmo de agrupamento (*clustering*) baseado na densidade, concebido para identificar agregados de pontos densamente concentrados e isolar, de forma automática, observações espúrias (*outliers*) ou ruído. Em vez de exigir a definição prévia de um número fixo de grupos, este método estabelece agrupamentos com base na proximidade e na densidade local dos dados, revelando-se altamente adequado para a análise de padrões

de condução irregulares ou condicionados por valores extremos. Esta abordagem permite detetar comportamentos distintos, mesmo quando a geometria espacial dos perfis de condução assume formas não lineares ou não esféricas.

2.3. Estimação envolvendo dados do sistema OBD II e adquiridos por sensores externos

Há trabalhos em que são combinados dados adquiridos através do sistema OBD-II com dados adquiridos por sensores externos, explorando a complementaridade entre variáveis macroscópicas da ECU e sinais de alta frequência provenientes de acelerómetros, giroscópios, GPS ou câmaras. Com a fusão destes dados, é possível caracterizar o comportamento de condução de forma mais completa, captando simultaneamente tendências globais, padrões dinâmicos e eventos microscópicos que não são observáveis apenas com dados provenientes do veículo.

Projetos naturalísticos de larga escala, como i-DREAMS e Rhapsody, analisados por [13] demonstram o potencial desta abordagem multimodal. Nestes sistemas, dados provenientes de GPS, acelerómetros, dos Sistemas Avançados de Assistência à Condução, conhecidos na literatura por Advanced Driver Assistance Systems (ADAS), e registos de dados gravados do computador de bordo são combinados para identificar perfis de risco com base em eventos agressivos, distâncias reduzidas (*headway*) (tempo que o veículo demoraria a chegar ao ponto onde se encontra o veículo da frente nesse exato momento), excessos de velocidade e indicadores de distração ou fadiga. Os autores mostram que a fusão de múltiplas fontes de dados melhora significativamente a capacidade de detetar comportamentos perigosos em cenários reais, reforçando a importância de abordagens híbridas em contextos de segurança rodoviária.

O trabalho apresentado em [23], integra simultaneamente dados provenientes do barramento CAN/OBD-II e sensores de *smartphone* para caracterizar acelerações longitudinais, laterais e padrões de travagem. O estudo demonstra que a combinação de métricas de conforto, eficiência e desgaste mecânico permitem construir perfis de condução multidimensionais, detetando detalhes que não seriam identificáveis com uma única fonte de dados. Esta abordagem evidencia a vantagem dos sistemas híbridos na deteção de padrões complexos e na avaliação do impacto do estilo de condução no desempenho mecânico do veículo.

Os autores do trabalho apresentado em [24], desenvolveram um sistema que adquire dados em tempo real através de um dispositivo *bluetooth* ligado ao conector OBD-II e de uma aplicação móvel, enviando a informação para uma plataforma analítica baseada em WSO2 DAS (plataforma de análise de dados). Os autores discriminam seis tipos de comportamentos anormais, incluindo acelerações bruscas, travagens intensas, movimentos laterais agressivos e variações súbitas de direção, classificando assim os condutores em categorias como *normal*, *below normal*, *abnormal* e *risky*. A solução integra ainda uma análise histórica, cálculo de métricas de agressividade e conforto, e disponibilização de perfis através de uma API. Este trabalho demonstra a eficácia de sistemas híbridos que combinam telemetria, análise em tempo real e processamento posterior de dados adquiridos, com aplicação direta em modelos de seguro automóvel baseados no comportamento do condutor, da terminologia anglo-saxónica Usage-Based Insurance (UBI), e na monitorização contínua do comportamento ao volante.

Mais recentemente, os autores do trabalho apresentado em [25] propuseram uma abordagem de telemática urbana em larga escala, combinando dados do veículo, GPS e informação contextual para mapear padrões de mobilidade e agressividade com elevada resolução espacial (15–150 m) e temporal (2 h). A metodologia Geospatial Spatio-Temporal Urban Mobility Model (GeoSTMUM) permite identificar segmentos de via com maior probabilidade de comportamentos agressivos, analisando os valores de *jerk*, volatilidade e perfis aceleração–velocidade. Este estudo demonstra que a integração de dados heterogéneos permite caracterizar não apenas o comportamento individual do condutor, mas também dinâmicas populacionais e padrões urbanos, reforçando o potencial dos sistemas mistos para aplicações em planeamento urbano, gestão de tráfego e segurança rodoviária.

Finalmente, o trabalho apresentado em [26] apresenta uma solução prática baseada em dados multimodais recolhidos no âmbito do projeto iDREAMS, integrando CAN, GPS, acelerómetros, ADAS e eventos de distração, fadiga e *headway*. O autor aplica técnicas de *clustering* (DBSCAN e Gaussian Mixture Model (GMM)) e modelos supervisionados (Random Forest, SVM, XGBoost, Decision Trees) para identificar perfis de condução não agressivo, agressivo e arriscado. Os resultados mostram que a fusão de dados de diferentes sensores permite capturar comportamentos inconsistentes ao longo do tempo e melhorar a precisão da classificação, demonstrando a aplicabilidade real dos sistemas mistos em contextos de monitorização contínua.

Os Gaussian Mixture Models [27] são modelos de *clustering* que representam os dados como uma combinação de várias distribuições estatísticas, permitindo formar grupos com formas mais flexíveis do que métodos baseados em distância fixa. Cada ponto é associado a um *cluster* com uma determinada probabilidade, o que torna o método adequado para perfis de condução com comportamentos sobrepostos ou transições graduais entre estilos. Esta abordagem é especialmente útil quando os dados não formam clusters bem definidos ou apresentam elevada variabilidade interna.

2.4. Padrões de condução e análise temporal

A análise temporal do estilo de condução constitui uma vertente essencial para compreender a estrutura sequencial do comportamento de um condutor ao volante de um veículo automóvel. Em vez de caracterizar o condutor através de médias ou contagens agregadas, estes estudos analisam sequências temporais de aceleração, travagem ou velocidade, identificando padrões repetitivos, *driving pulses* e relações dinâmicas entre variáveis.

O estudo apresentado em [28] é particularmente relevante, analisando o *jerk* médio como indicador central do comportamento longitudinal. Os autores demonstram que condutores com maior variabilidade na aceleração tendem a apresentar valores de *jerk* mais elevados, refletindo uma condução mais intensiva e irregular. Este trabalho introduz um fator latente associado ao estilo de condução longitudinal, o qual se manifesta simultaneamente em múltiplas métricas derivadas da dinâmica do veículo.

A investigação apresentada em [29], que utiliza os valores de *jerk* como base para a métrica central para classificar o comportamento de um condutor em calmo, normal e agressivo, com base no rácio entre o desvio padrão do *jerk* e um valor de referência. Este estudo destaca a importância das derivadas de ordem superior da aceleração para a caracterização de padrões de condução.

A literatura recente, incluindo revisões como a de [30], demonstra que metodologias orientadas à análise temporal, nomeadamente Dynamic Time Warping (DTW), *driving pulses* e modelos recorrentes como Long Short-Term Memory (LSTM) e Gated Recurrent Unit (GRU), que permitem caracterizar o comportamento de condução de forma mais detalhada do que abordagens baseadas em métricas agregadas. Neste estudo, os autores aplicam estas técnicas a séries temporais reais de velocidade e aceleração, identificando padrões dinâmicos associados a três perfis distintos de condução: não agressivo, agressivo e

arriscado. A análise temporal revela dependências de curto e longo prazo que ajudam a detetar comportamentos como inconsistência, variações abruptas, fadiga ou distração, evidenciando o potencial destas abordagens para capturar nuances que não seriam observáveis através de métodos tradicionais.

O Dynamic Time Warping [31] é um método de comparação de séries temporais que permite medir a semelhança entre duas sequências mesmo quando estão desalinhadas no tempo. Em vez de comparar ponto a ponto, o DTW ajusta elasticamente o eixo temporal para encontrar o melhor alinhamento entre as duas curvas, compensando diferenças de velocidade, duração ou pequenas variações no ritmo dos dados. Este método é especialmente útil em perfis de condução porque permite comparar trajetórias de aceleração, velocidade ou de VRM entre condutores, mesmo quando os eventos não ocorrem exatamente no mesmo instante. Assim, o DTW consegue identificar padrões semelhantes de comportamento de condução mesmo em sequências irregulares ou com diferentes durações.

A Long Short-Term Memory é um tipo de rede neuronal recorrente concebida para analisar sequências de dados, capaz de manter informação relevante ao longo do tempo através de mecanismos internos de memória [32]. Este modelo aprende dependências de curto e longo prazo, o que o torna adequado para séries temporais como aceleração, velocidade do veículo ou VRM. As LSTM são eficazes para identificar padrões de condução que evoluem ao longo do tempo, mesmo quando os eventos não ocorrem exatamente no mesmo instante.

As redes recorrentes GRU são semelhantes às LSTM mas com uma estrutura interna mais simples, utilizando menos portas de controlo [33]. Esta simplificação reduz a complexidade computacional e acelera o treino, mantendo a capacidade de aprender relações temporais nos dados. As GRU são adequadas para analisar sequências de condução e capturar padrões dinâmicos, sendo especialmente úteis quando se pretende um modelo mais leve sem perda significativa de desempenho.

2.5. Análise comparativa

A diversidade de abordagens para a estimação de perfis de condução identificada nos subcapítulos anteriores evidencia que a caracterização do comportamento de condução pode assumir múltiplas formas, dependendo das fontes de dados utilizadas, das variáveis selecionadas e das técnicas de processamento aplicadas. Embora cada estudo apresente objetivos específicos e metodologias próprias, a comparação sistemática entre estas permite

identificar tendências comuns, complementaridades e limitações que influenciam diretamente o desenvolvimento de soluções de monitorização e classificação de perfis de condução. Para sintetizar esta informação de forma clara e objetiva, a Tabela 1 apresenta uma análise comparativa dos principais estudos revistos, organizada segundo assuntos transversais a toda a literatura: fonte de dados, variáveis utilizadas, técnicas ou algoritmos aplicados, número de perfis, objetivos do estudo, e limitações identificadas nos estudos, a ordem dos artigos é descrita na tabela conforme a ordem das citações desses mesmos artigos neste documento. Esta tabela permite, não apenas comparar metodologias distintas, mas também compreender como diferentes escolhas experimentais influenciam os resultados obtidos. A análise desta tabela fornece uma visão integrada da revisão bibliográfica, destacando as vantagens e limitações de cada abordagem, servindo de base para justificar as opções metodológicas adotadas no capítulo seguinte.

A análise comparativa evidencia diferenças marcantes entre as abordagens existentes, tanto ao nível das fontes de dados como das metodologias utilizadas. Os estudos baseados em dados adquiridos exclusivamente pelo conector OBD-II tendem a privilegiar variáveis relacionadas com a movimentação longitudinal e métricas diretamente relacionadas com o funcionamento do motor, permitindo identificar padrões de aceleração, travagem e eficiência energética com elevada precisão. No entanto, estes trabalhos revelam limitações estruturais, sobretudo pela ausência de informação lateral e pela baixa frequência de amostragem, o que restringe a capacidade de detetar comportamentos mais complexos ou eventos de curta duração.

Por outro lado, os estudos que recorrem a sensores de *smartphone* apresentam maior riqueza dinâmica, captando acelerações tridimensionais, rotações e variações rápidas no movimento do veículo. Esta abordagem permite detetar eventos agressivos com elevada sensibilidade, mas introduz desafios associados ao ruído dos sensores, à variabilidade da posição do dispositivo e à necessidade de pré-processamento intensivo.

Os sistemas mistos surgem como uma solução intermédia, combinando a robustez dos dados adquiridos pelo sistema OBD-II com a capacidade dos sensores externos. Estes estudos demonstram maior capacidade de caracterização multidimensional e revelam-se particularmente eficazes na identificação de comportamentos de risco, embora impliquem maior complexidade técnica e custos de implementação superiores.

Tabela 1 - Comparação das abordagens existentes na literatura

Artigo	Fonte de dados	Variáveis utilizadas	Técnicas/ Algoritmos	Nº de perfis	Objetivos do estudo	Limitações
[1]	OBD-II	Velocidade, derivada da aceleração e carga do motor	AdaBoost	2	Classificar o estilo de condução como agressivo ou normal	Classifica apenas em 2 níveis tornando-se limitado e generalista
[3]	OBD-II e IVDR	Velocidade, rotação do motor, aceleração, travagem, posição do acelerador, entre outros PIDs	Estatísticas descritivas, análise das variáveis adquiridas, comparação dos condutores	NA	Comparar comportamentos de condução entre diferentes condutores	Sem validação experimental e não classifica o perfil de condução
[4]	OBD-II	Aceleração, velocidade, travagem	K-Means; Rand Index	3	Agrupar viagens de condutores em 3 perfis distintos	O algoritmo é facilmente influenciado por valores externos, podendo gerar erros de classificação de perfis
[6]	OBD-II	Velocidade, aceleração, travagem	KNN; ELM	3	Comparar o método KNN e o ELM para atribuir 3 perfis de condução	Dependência de normalizar os dados, não analisa como diferentes combinações de variáveis influenciam os perfis
[9]	OBD-II	Velocidade, rotação do motor, posição do acelerador, carga do motor	Regras heurísticas (definidas manualmente)	3	Definir 3 perfis de condução com base em regras definidas manualmente	Perfis dependem apenas de métricas definidas pelo autor, tornando-se regras manuais subjetivas
[10]	OBD-II de veículos elétricos	Velocidade, estado da bateria, autonomia, consumo energético	Análise estatística: médias, variâncias, correlações	NA	Avaliar impacto do tipo da condução na autonomia do veículo	Não identifica perfis e apenas pode ser utilizado em veículos elétricos
[11]	OBD-II	Velocidade, rotação do motor, posição do acelerador, carga do motor, consumo instantâneo	SVM, Decision Trees, Random Forest, Logistic Regression	3	Definir 3 perfis de condução comparando todas as técnicas utilizadas	A qualidade dos resultados depende de dados rotulados, o modelo aprende com os dados fornecidos e tem dificuldade em se adaptar a novos dados

[16]	Acelerómetro, giroscópio, GPS	Aceleração 3D, rotação do motor, velocidade	ANN, SVM, Random Forest	3	Detetar eventos agressivos da condução com recurso a um smartphone	Ruído dos sensores dos smartphones, depende da posição do smartphone
[17]	OBD-II, GPS, apps	Velocidade	Análise comparativa das variáveis adquiridas	NA	Comparar as medições realizadas com os 3 métodos utilizados	Foco apenas na velocidade e não identifica perfis de condução
[18]	Acelerómetro	Aceleração longitudinal, velocidade	Regras heurísticas (definidas manualmente)	3	Classificar o condutor como normal, agressivo ou perigoso com limites definidos manualmente	Perfis dependem apenas de limites fixos que podem não refletir a realidade, apenas desenvolvido para veículos de duas rodas
[19]	Smartphone	Aceleração, velocidade, travagem, emissões de gases, consumo energético	K-Means; SUMO	3	Classificar 3 perfis de condução e analisar o impacto das emissões do veículo para cada perfil	Dependência de simulação que pode não ser realista
[20]	GPS + condições da estrada	Velocidade, aceleração, limite de velocidade, tipo de via, geometria da estrada, condições de trânsito e ambientais	DBSCAN; J48	3	Detetar padrões de condução considerando o contexto da estrada e classificar comportamentos	Dependência de dados das estradas que nem sempre são completos
[22]	GPS, acelerómetros, sistema ADAS, IVDR	Headway (ADAS), velocidade, aceleração, eventos, fadiga	Modelos multimodais (combina todos os dados para os analisar)	3	Integrar todos os dados para identificar padrões de risco e fadiga	Integração multimodal aumenta a complexidade e o risco de dessincronização entre sensores
[23]	OBD-II e <i>smartphone</i>	Aceleração longitudinal e lateral, travagem, velocidade	PCA, correlações, análise de padrões	2	Definir 2 perfis de condução com dados de aceleração travagem e velocidade	PCA reduz variáveis o que pode perder informações importantes
[24]	OBD-II, GPS, <i>smartphone</i>	Aceleração, velocidade, travagem, movimentos laterais	Regras definidas manualmente; REST API	3	Detetar comportamentos anormais e enviar os dados para um servidor	Regras fixas e definidas manualmente limitam a flexibilidade e a capacidade de adaptação
[25]	OBD-II, GPS, contexto urbano	Jerk, velocidade, aceleração, localização GPS, limite	GeoSTMUM	3	Classificar condutores considerando os dados do veículo	Complexidade, elevado custo computacional,

		velocidade, tipo de via, geometria da estrada			com os dados da estrada onde circula	dependência do contexto urbano
[26]	OBD-II, GPS, acelerômetro, Sistema ADAS	<i>Headway</i> (ADAS), aceleração, velocidade	DBSCAN, GMM, Random Forest, SVM	3	Classificar perfis integrando múltiplos sensores aplicando métricas avançadas	Múltiplas fontes o que tem riscos de não estarem todos os dados sincronizados
[28]	Sensores longitudinais	<i>Jerk</i> , velocidade, aceleração	Análise estatística (variabilidade e correlações)	3	Utilizar métricas estatísticas para definir 3 perfis de condução	Utiliza métricas simples podendo não classificar padrões mais complexos
[29]	Não especificado	<i>Jerk</i> , aceleração	Regras heurísticas (definidas manualmente)	3	Classificar estilos de condução com base em limites de aceleração e <i>jerk</i>	Perfis que dependem apenas de métricas definidas pelo auto
[30]	OBD-II, GPS, acelerômetro	Velocidade, aceleração, padrões de condução	DTW; LSTM; GRU	3	Definir padrões ao longo do tempo, comparando séries temporais	Requer <i>datasets</i> longos, complexidade, elevado custo computacional

Finalmente, as abordagens centradas na análise temporal destacam-se por captarem a estrutura sequencial do comportamento de condução, identificando padrões que não dependem exclusivamente de métricas agregadas. Métricas como *jerk*, *driving pulses* ou dependências temporais permitem compreender a consistência do estilo de condução ao longo do tempo, mas exigem *datasets* extensos e técnicas de modelação mais avançadas.

Para além das diferenças nas fontes de dados, a literatura evidencia também uma diversidade significativa nos métodos de processamento aplicados à caracterização do comportamento de condução. Os estudos analisados recorrem tanto a técnicas de classificação supervisionada, como SVM, Random Forest, AdaBoost ou redes neuronais, utilizadas para distinguir perfis de condução previamente rotulados, como a métodos de *clustering* não supervisionado, nomeadamente K-Means e DBSCAN, que permitem identificar padrões emergentes sem necessidade de anotação manual. Os métodos supervisionados tendem a apresentar elevada precisão quando existe um conjunto de treino representativo, mas dependem fortemente da qualidade dos rótulos. Já as abordagens de *clustering* revelam-se úteis na descoberta de grupos naturais de condutores ou eventos de condução, embora sejam sensíveis à escolha das métricas de distância e à escala dos dados. Em ambos os casos, o desempenho dos modelos depende de etapas prévias de processamento, como filtragem,

normalização, segmentação temporal e extração de características, que variam consoante a natureza dos dados utilizados.

De uma forma global, pode concluir-se que não haverá uma abordagem para a estimação de perfis de condução que se distinga excecionalmente das outras. Cada estudo ou trabalho demonstra vantagens específicas, mas apresenta sempre algumas limitações próprias. A revisão bibliográfica apresentada neste capítulo estabelece o enquadramento necessário para justificar as opções tomadas no desenvolvimento do trabalho relatado neste documento.

3. Sistema de aquisição e registo de dados

Neste capítulo é apresentada a solução desenvolvida para o sistema de aquisição e registo de dados, começando pela arquitetura geral do sistema, onde se descreve a organização geral e a interligação entre os seus principais componentes. Depois são efetivamente detalhados os desenvolvimentos do *hardware* e do *firmware* do sistema.

O sistema desenvolvido foi concebido segundo uma arquitetura integrada, na qual o *hardware* e o *firmware* asseguram as funções de aquisição e registo de dados, merecendo cada uma destas vertentes uma abordagem detalhada nas secções subsequentes. Na Figura 3-1 está ilustrado o diagrama de blocos da arquitetura geral do sistema.




Figura 3-1 – Diagrama de blocos da arquitetura geral do sistema

3.1.Desenvolvimento do *hardware*

O desenvolvimento do sistema exigiu a seleção de uma arquitetura de *hardware* capaz de garantir fiabilidade, baixo consumo energético e compatibilidade com a maioria dos veículos equipados com protocolo OBD-II. Para tal, foi adotada uma solução modular composta por quatro elementos principais, sendo eles: o microcontrolador, o *transceiver* CAN, o conector

do sistema OBD-II e o módulo de registo em cartão de memória. Cada elemento foi escolhido de forma a assegurar robustez, facilidade de integração e capacidade de expansão futura.

3.1.1. Microcontrolador

O microcontrolador utilizado foi o ESP32, uma solução de baixo custo que integra módulos de *WiFi* e *Bluetooth*, tornando-o versátil para aplicações em sistemas embarcados com requisitos de comunicação. Este dispositivo incorpora um processador dual core com frequência de relógio ajustável, permitindo executar tarefas de aquisição e processamento de dados em paralelo, mantendo um consumo energético reduzido.

O microcontrolador dispõe de dois tipos de memória interna utilizada para armazenamento temporário de dados e instruções durante a execução do *firmware*, e memória *flash*, responsável por guardar o programa e os ficheiros necessários ao funcionamento do sistema. Para além disso, este microcontrolador disponibiliza um conjunto alargado de interfaces de comunicação (UART, SPI, I2C e CAN).

Uma das vantagens mais relevantes é a existência de uma comunidade de desenvolvimento muito ativa, acompanhada por bibliotecas estáveis e documentação extensa, o que facilita a implementação de novas funcionalidades e acelera o processo de desenvolvimento. O ESP32 pode ser programado em diversas linguagens, incluindo C/C++ e *Python*, oferecendo flexibilidade ao programador.

A Figura 3-2, apresenta o microcontrolador ESP32 WROOM de 38 terminais utilizados no sistema e o respetivo *pinout*, destacando a disponibilidade de terminais dedicados às diferentes interfaces de comunicação necessárias para a integração com o *transceiver* CAN, o módulo microSD e os restantes componentes do sistema.




Figura 3-2 - Identificação dos terminais da placa ESP32 ESP-WROOM-32

Para alimentar o microcontrolador é necessária uma tensão de 5 V. No habitáculo dos veículos é comum existir uma tomada de isqueiro que disponibiliza 12 V, pelo que se recorreu a esta fonte para alimentar o sistema. Para converter os 12 V do veículo para os 5 V requeridos pelo microcontrolador, foi utilizado um conversor DC-DC (adaptador de isqueiro), ilustrado na Figura 3-3.

Este adaptador possui uma saída USB fêmea, permitindo a ligação direta ao ESP32 através de um cabo USB-A macho para USB-C macho. Desta forma, garante-se uma alimentação estável e compatível com os requisitos elétricos do microcontrolador, mantendo simultaneamente a simplicidade de instalação no veículo.



Figura 3-3 – Adaptador de isqueiro

3.1.2. Módulo *transceiver* CAN

No sistema de aquisição desenvolvido foi utilizado o *transceiver* CAN, MCP2551, um dispositivo de alta velocidade amplamente utilizado em aplicações automóveis devido à sua robustez elétrica e conformidade com a norma ISO 11898, que define os requisitos físicos da comunicação em redes CAN (Figura 3-4). Este componente atua como *interface* entre o microcontrolador e a rede CAN do veículo, convertendo os níveis lógicos do ESP32 nos níveis diferenciais necessários para a transmissão e recepção de mensagens CAN. Além disso, o MCP2551 é totalmente compatível com o protocolo ISO 15765 CAN, utilizado pela maioria dos veículos modernos para comunicação OBD-II.

O *transceiver* suporta velocidades até 1 Mbit/s, garantindo compatibilidade com a maioria das redes CAN presentes em veículos ligeiros modernos. Esta elevada velocidade de comunicação foi um requisito fundamental para o desenvolvimento deste projeto, uma vez que a aquisição de dados em tempo real exige tempos de resposta reduzidos e elevada fiabilidade na transmissão das tramas CAN. Por este motivo, o MCP2551 foi selecionado como *transceiver* dedicado, assegurando desempenho consistente mesmo em condições de ruído e variações de tensão típicas do ambiente automóvel.

A integração do MCP2551 com o ESP32 é realizada através de pinos dedicados às linhas TX e RX, permitindo que o microcontrolador envie e receba mensagens CAN após a conversão elétrica efetuada pelo *transceiver*. As linhas CAN *High* (CANH) e CAN *Low* (CANL) são ligadas diretamente ao conector OBD-II, possibilitando o acesso à rede de comunicação do veículo.




Figura 3-4 - Módulo *transceiver* MCP2551

Para estabelecer a ligação entre o *transceiver* MCP2551 e a rede CAN do veículo, foi utilizada uma ficha OBD-II, como ilustrado na Figura 3-5 a), que constitui o padrão universal para acesso aos sistemas de diagnóstico automóvel. Esta ficha disponibiliza as linhas de

comunicação CAN *High* (terminal 6) e CAN *Low* (terminal 14), visíveis na Figura 3-5 b), necessárias para a transmissão e receção de mensagens CAN segundo o protocolo ISO 15765. No presente projeto, o terminal 6 foi ligado diretamente ao terminal CANH do MCP2551, enquanto o terminal 14 foi ligado ao terminal CANL, assegurando a correta *interface* elétrica com a rede CAN do veículo.




Figura 3-5 – Ficha OBD-II: a) aspeto exterior e b) identificação dos terminais

3.1.3. Módulo de cartões de memória

Um módulo de cartões microSD, como o da Figura 3-6, é um dispositivo que possibilita a comunicação com este tipo de cartões de memória. A comunicação entre o microcontrolador e o cartão de memória é realizada utilizando o protocolo Serial Peripheral Interface (SPI).



Figura 3-6 - Cartão microSD de 16GB e respetivo módulo

3.1.4. Sistema desenvolvido

O diagrama de blocos apresentado na Figura 3-7 representa o sistema de aquisição e registo de dados provenientes da rede CAN do veículo através do sistema OBD-II.

O conetor OBD-II do veículo permite aceder às linhas de comunicação CAN *High* (terminal 6) e CAN *Low* (terminal 14). Estas linhas da rede CAN seguem o protocolo ISO 15765, amplamente utilizado em veículos modernos. Os sinais provenientes da ficha OBD-II são

encaminhados para o *transceiver* MCP2551, responsável por converter os níveis diferenciais da rede CAN em níveis lógicos compatíveis com o microcontrolador.

A comunicação entre o MCP2551 e o microcontrolador ESP32 é realizada através das linhas TX e RX do seu controlador CAN. Para o registo local de dados em cartões microSD, o ESP32 comunica com um módulo para esse através de uma *interface* SPI.

O sistema inclui ainda um botão START, utilizado para iniciar manualmente o processo de aquisição, e um LED indicador, que fornece *feedback* visual sobre o estado de funcionamento do sistema. Ambos estão ligados diretamente ao ESP32, que controla o seu comportamento.

A alimentação do sistema é assegurada por um conversor DC-DC de 12 V para 5 V, ligado à tomada de isqueiro do veículo. Este conversor fornece a tensão necessária para o funcionamento do ESP32 e dos restantes módulos, garantindo estabilidade e proteção contra variações de tensão típicas num veículo automóvel.

A integração destes componentes resulta num sistema compacto, robusto e capaz de adquirir dados CAN em tempo real, registando-os de forma fiável para posterior processamento.




Figura 3-7 - Diagrama de blocos do sistema de aquisição e registo de dados

A Figura 3-8 apresenta o esquema elétrico do sistema desenvolvido para aquisição e registo de dados. O circuito integra todos os módulos necessários para a obtenção, processamento e registo dos dados provenientes do sistema OBD-II do veículo.

Impresso (PCI), apresentada na Figura 3-10. Para esta etapa foi utilizado o *software* KiCad, onde foi elaborado o esquema elétrico final e posteriormente o *layout* da placa. Esta transição permitiu consolidar todas as ligações testadas no protótipo, otimizar o encaminhamento dos sinais e garantir uma solução mais robusta, compacta e adequada à sua instalação no interior do veículo.





Figura 3-10 – Vista inferior da PCI desenvolvida

Durante o processo de integração dos componentes eletrônicos, foi igualmente desenvolvido no *software* SolidWorks o modelo tridimensional da caixa destinada a alojar o sistema. O desenho 3D, apresentado na Figura 3-11, foi concebido de forma a garantir a proteção mecânica dos módulos internos e a organização da cablagem, assegurando simultaneamente dimensões compactas e compatíveis com a instalação no interior do veículo. A modelação permitiu validar o posicionamento dos elementos, otimizar o espaço disponível e preparar a peça para fabrico por impressão 3D, resultando numa solução estrutural robusta e adaptada às exigências do ambiente automóvel.



a) b)
Figura 3-11 – Desenho 3D da caixa: a) caixa e b) tampa

O protótipo final, apresentado na Figura 3-12, incorpora a placa de circuito impresso, os módulos de comunicação, a alimentação e todos os elementos necessários ao funcionamento autónomo do sistema. A montagem final foi realizada de forma a garantir robustez mecânica, organização interna e facilidade de acesso aos conectores, permitindo a instalação segura no interior do veículo. O resultado é um dispositivo compacto, fiável e preparado para operar em ambiente real, representando a transição definitiva do protótipo inicial, ainda em *breadboard*, para esta versão definitiva.



Figura 3-12 – Protótipo final do sistema de aquisição e registo de dados: a) vista interior e b) vista exterior

3.2.Desenvolvimento do *firmware*

O *firmware* desenvolvido para o microcontrolador ESP32 consiste num sistema de aquisição e registo de dados, assegurando a comunicação com o sistema OBD-II, o processamento das mensagens CAN provenientes da ECU do veículo e o registo dos dados recolhidos para pós-processamento.

A Figura 3-13 apresenta o fluxograma geral do *firmware*, ilustrando a sequência de operações realizadas pelo microcontrolador desde a inicialização até ao processo de aquisição contínua.

Inicialização dos módulos do sistema

O *firmware* inicia com a configuração dos periféricos essenciais ao funcionamento do sistema. A porta série é ativada para permitir a monitorização do comportamento do *firmware* durante a fase de desenvolvimento e validação. Em seguida, são configurados o

LED indicador do estado do sistema e o botão de controlo do mesmo, sendo este último utilizado para alternar entre os estados de operação.

A inicialização do cartão microSD é realizada através da *interface* SPI, verificando-se a disponibilidade do cartão e criando-se automaticamente um ficheiro em formato Comma-Separated Values (CSV) caso este ainda não exista. Esta etapa assegura que o sistema se encontra preparado para armazenar dados antes de iniciar qualquer sessão de aquisição.

É configurado o módulo CAN interno do microcontrolador ESP32, definindo-se os terminais de transmissão e receção, a velocidade do barramento (500 kbps) e o filtro de mensagens. Por fim, é também configurada a função de *callback* responsável por tratar as respostas provenientes da ECU, permitindo que o processamento das mensagens CAN ocorra de forma assíncrona. Desta forma, assim que a ECU envia uma resposta ao pedido realizado, o microcontrolador ESP32 executa automaticamente a função associada ao *callback*.

Máquina de estados e controlo do processo de aquisição

O sistema assenta numa máquina de estados simples, alternando entre os modos INATIVO e ATIVO, controlados através de um botão físico. No estado INATIVO, o sistema permanece em espera (ligado, mas sem aquisição e registo de dados ativos). No estado ATIVO inicia o envio periódico de pedidos ao protocolo OBD-II, o processamento das respostas CAN e o registo dos dados no cartão microSD em formato CSV, acrescentado um *timestamp*. Além disso, neste estado ATIVO, há um LED que permanece ligado para sinalizar visualmente este estado.

Envio periódico de pedidos ao sistema OBD-II

Durante o estado ATIVO, o ESP32 envia ciclicamente pedidos ao sistema OBD II utilizando o identificador 0x7DF (segundo o modo 01 do protocolo OBD-II) para o PID 0x0C, que corresponde à VRM, e o PID 0x0D, que corresponde à velocidade do veículo. Estes pedidos são realizados a intervalos de 1 segundo, garantindo uma taxa de amostragem estável e adequada à análise dinâmica do comportamento de condução.




Figura 3-13 - Fluxograma do *firmware* desenvolvido

Processamento das respostas CAN

As respostas da ECU são tratadas pela função de *callback* associada ao identificador 0x7E8, correspondente às mensagens de resposta aos pedidos OBD-II. Nesta função são extraídos os valores da VRM e velocidade do veículo, sendo posteriormente calculada a aceleração longitudinal com base nas diferenças de velocidade e de tempo entre aquisições

consecutivas. Cada conjunto de dados é sincronizado com um registo temporal em segundos (*timestamp*), assegurando a integridade e ordenação cronológica dos registos.

No caso da VRM, em resposta ao PID 0x0C, este PID devolve dois *bytes* de dados, designados por A e B, onde A corresponde ao Most Significant Byte (MSB) e B ao Least Significant Byte (LSB). A reconstrução do valor real é feita através da seguinte equação:

$$\frac{256 \times A + B}{4}$$

Na equação anterior, a multiplicação de A por 256 desloca o *byte* mais significativo para a esquerda, permitindo recompor o valor de 16 *bits* enviado pela ECU. A divisão final por 4 resulta da resolução do PID, uma vez que cada unidade transmitida representa 0.25 rpm. Este processo faz parte da descodificação dos PIDs OBD-II, necessária para converter os *bytes* recebidos em valores físicos interpretáveis.

Já no caso da velocidade, correspondente ao PID 0x0D, a ECU envia apenas um único *byte*. Este *byte* representa diretamente a velocidade em km/h, não sendo necessária qualquer combinação ou descodificação adicional.

Registo dos dados em cartão memória

O registo dos dados é realizado através da escrita sequencial no ficheiro em formato CSV. Cada linha contém o valor do tempo em segundos de cada aquisição, o valor da VRM, a velocidade do veículo e a aceleração calculada. O ficheiro é aberto e fechado a cada operação de escrita, reduzindo o risco de corrupção em caso de falha de alimentação do sistema.

4. Desenvolvimento do método de estimação

O presente capítulo aborda o desenvolvimento de um método para a avaliação do comportamento dos condutores de veículos automóveis. A estimação do perfil de condução é realizada através da classificação heurística dos dados (em ambiente Matlab), analisando-se o impacto de diferentes combinações de variáveis, especificamente a velocidade, a aceleração e o *jerk*. Com base na definição de limiares para estas grandezas, o comportamento é categorizado em três níveis distintos de severidade: leve, moderado e agressivo. De forma a determinar a combinação mais eficaz e precisa, os resultados da estimação são confrontados e validados analiticamente tendo como referência dois percursos previamente anotados. Estes percursos de referência foram realizados em ambiente real de condução, ao longo das quais se registou manualmente, e em tempo real, o perfil adotado pelo condutor em cada instante.

A validação do método para diversas combinações de variáveis e limiares é efetuada através da análise comparativa dos histogramas resultantes da classificação de dados com os histogramas correspondentes aos percursos de referência. Esta comparação permite verificar eventuais diferenças na proporção de cada perfil de condução, que são expressas qualitativamente na forma de erros absoluto e percentual, calculados da forma que se apresenta a seguir:

$$|erro\ absoluto| = |valor\ obtido - valor\ de\ referência|$$

$$erro\ percentual[\%] = \frac{|erro\ absoluto|}{valor\ de\ referência} \times 100.$$

A Figura 4-1 apresenta os histogramas correspondentes à distribuição dos perfis de condução registados nos percursos de referência 1 e 2, constituindo a base utilizada para a validação do método de estimação abordados, envolvendo a classificação heurística de dados. No percurso 1, o perfil leve representa 84.9% das ocorrências, seguido do perfil moderado com 10.7% e do perfil agressivo com 4.4%. Esta distribuição revela uma predominância clara da condução leve, mas ainda com uma presença significativa do perfil moderado, sugerindo alguma variabilidade nos comportamentos de condução ao longo do percurso. Por outro lado, no percurso 2, o perfil leve aumenta para 92.9%, enquanto o perfil moderado (3.5%) e agressivo (3.7%) apresentam valores bastante reduzidos e muito próximos entre si. Esta

configuração indica uma distribuição mais concentrada e homogênea, com uma quase total dominância do perfil de condução leve.




Figura 4-1 – Histogramas dos dois percursos de referência: a) percurso 1 e b) percurso 2

4.1. Leitura e preparação inicial dos dados

Os dados utilizados para o desenvolvimento do método de estimação de perfis de condução são os proporcionados pelo sistema de aquisição e registo de dados instalado no veículo usado, referentes à velocidade do veículo e à VRM, e os correspondentes instantes temporais de aquisição.

Numa fase inicial de testes foram utilizados vários veículos automóveis, contudo o mais utilizado na parte do final do trabalho foi um Volkswagen Golf Mark VII GTD, equipado com um motor 2.0 TDI (Turbo Diesel Injection), do ano de 2013, conforme ilustrado na Figura 4-2.



Figura 4-2 - Volkswagen Golf Mark VII 2.0 TDI GTD (2013)

O primeiro passo do processamento consiste na leitura automática dos ficheiros em formato CSV gerados durante os testes, contendo o registo dos dados adquiridos. Após essa leitura procede-se a uma verificação e filtragem inicial dos dados. Em particular, os valores baixos de VRM, inferiores a 750 rpm, são corrigidos para esse limite mínimo, uma vez que representam momentos de desligar e voltar a ligar o motor, podendo introduzir erros no método desenvolvido. Esta etapa assegura que o conjunto de dados se encontra num estado consistente antes da aplicação do método de estimação.

A velocidade fornecida pelo sistema de aquisição é disponibilizada em km/h, uma vez que os valores obtidos através da *interface* OBD-II são automaticamente convertidos para esta unidade. Para efeitos de processamento e cálculo das grandezas derivadas, é necessário expressar a velocidade em m/s, pelo que se procede à respetiva conversão. A aceleração longitudinal do veículo é posteriormente calculada a partir da diferença entre amostras consecutivas de velocidade, de acordo com a expressão:

$$a(t_i) = \frac{v(t_i) - v(t_{i-1})}{t_i - t_{i-1}}$$

Este procedimento permite obter um vetor de aceleração ponto a ponto, essencial para a classificação do estilo de condução.

O *jerk*, definido como a derivada temporal da aceleração (longitudinal, no caso), é calculado de forma semelhante:

$$j(t_i) = \frac{a(t_i) - a(t_{i-1})}{t_i - t_{i-1}}$$

Como o cálculo do *jerk* requer duas acelerações consecutivas, este só pode ser obtido a partir da terceira amostra. Para manter a coerência temporal do vetor de dados, os primeiros valores são preenchidos com NA (Não Aplicável).

4.2. Estimação baseada na aceleração

A estimação do perfil de condução baseada na classificação heurística da aceleração é realizada para cada amostra. Os valores da aceleração são comparados com os limiares previamente definidos para distinguir entre condução leve, moderada e agressiva.

Nos artigos [20] e [11] foram definidos limiares de aceleração para a classificação do perfil de condução, os quais se apresentam na Tabela 2.

Tabela 2 - Limiares de aceleração para a estimação do perfil de condução segundo [20] e [11]

Perfil de condução	Aceleração [m/s^2]
Perigoso	[-9.0 a -14.0] ou [7.0 a 12.0]
Agressivo	[-5.5 a -9.0] ou [3.5 a 7.0]
Normal	[-3.0 a -5.5] ou [1.5 a 3.5]
Seguro	[0 a -3.0] ou [0 a 1.5]

Como nos percursos de referência não houve uma aceleração superior a 7.0 m/s^2 nem uma desaceleração inferior a -14.0 m/s^2 , entendeu-se categorizar os perfis de condução em leve, moderado e agressivo, sendo que o perfil agressivo corresponde a acelerações superiores a 3.5 m/s^2 e desacelerações inferiores a -5.5 m/s^2 , tal como pode ser visualizado na Tabela 3.

Tabela 3 - Limiares de aceleração adaptados para a estimação do perfil de condução

Perfil de condução	Aceleração [m/s^2]
Agressivo	<-5.5 ou >3.5
Moderado	[-3.0 a -5.5] ou [1.5 a 3.5]
Leve	[0 a -3.0] ou [0 a 1.5]

Os autores do artigo [24] definiram limiares diferentes de aceleração para a classificação do perfil de condução (Tabela 4), assim sendo, esses valores foram também considerados para a estimação dos perfis de condução.

Tabela 4 - Limiares de aceleração para estimação do perfil de condução segundo [24]

Perfil de condução	Aceleração [m/s^2]
Agressivo	<-2.74 ou >2.74
Normal	[-2.74 a 2.74]

A estimação dos dados baseada na classificação da aceleração longitudinal que se propõe assenta em limiares definidos empiricamente, determinados a partir dos vários testes experimentais realizados ao longo do desenvolvimento deste trabalho de projeto. Os limiares de aceleração utilizados estão apresentados na Tabela 5.

Tabela 5 - Limiares de aceleração propostos para a estimação do perfil de condução

Perfil de condução	Aceleração [m/s ²]
Agressivo	[<-4] ou [>3]
Moderado	[-2 a -4] ou [1,5 a 3]
Leve	[0 a -2] ou [0 a 1,5]

A Figura 4-3 apresenta os histogramas correspondentes à estimação dos perfis de condução por classificação de dados de aceleração longitudinal durante o percurso de referência 1, envolvendo Limiares de aceleração propostos pelos autores dos artigos [20] e [11], pelos autores do artigo [24], e os propostos para este trabalho.




Figura 4-3 – Histogramas correspondentes ao percurso de referência 1; a) Limiares de aceleração dos artigos [20] e [11]; b) limiares de aceleração do artigo [24]; c) limiares de aceleração propostos para este trabalho

De seguida, são apresentados os resultados correspondentes à classificação dos dados de aceleração correspondentes ao percurso de referência 2.

A Figura 4-4 apresenta os histogramas correspondentes à estimação dos perfis de condução utilizando os dados de aceleração longitudinal durante o percurso de referência 2, envolvendo limiares de aceleração apresentados pelos autores dos artigos [20] e [11], pelos autores do artigo [24], e os propostos para este trabalho.




Figura 4-4 – Histogramas correspondentes ao percurso de referência 2; a) limiares de aceleração dos artigos [20] e [11]; b) limiares de aceleração do artigo [24]; c) limiares de aceleração propostos para este trabalho

De forma a tornar possível a comparação dos resultados obtidos em [24] com os resultados do percurso de referência 1, procedeu-se à soma das percentagens correspondentes aos perfis moderado e agressivo dos percursos de referência, dado que o referido artigo caracteriza apenas dois tipos de perfil de condução.

A análise do erro absoluto, apresentada na Tabela 6, evidencia que o método proposto com os limiares de aceleração apresenta, de forma consistente, os desvios mais reduzidos face

aos valores esperados, superando claramente os resultados envolvendo os limiares propostos nos artigos [24], [11] e [20]. Isto corrobora a pertinência dos limiares propostos para a classificação dos dados de aceleração e a validade da estimação dos perfis de condução, nomeadamente nas categorias moderado e agressivo.

A análise do erro percentual evidencia que a estimação considerando os limiares de aceleração aqui propostos, apresenta, de forma consistente, erros mais reduzidos nos três perfis de condução, comparativamente ao que resulta da consideração dos limiares propostos em [24], [11] e [20]. Os limiares de aceleração que estes consideram revelam discrepâncias significativamente superiores, em particular nos perfis moderado e agressivo, enquanto o método proposto demonstra uma aproximação mais fiel aos valores esperados.

Os valores do erro percentual tornam-se elevados quando os valores de referência são muito próximos de zero, uma vez que pequenas diferenças absolutas resultam em variações percentuais desproporcionadamente grandes.

Tabela 6 - Erros obtidos na estimação usando a aceleração

Limiares utilizados	Tipo de Percurso	Perfil de Condução	Erro Absoluto	Erro Percentual (%)
Descritos em [11] e [20]	Percurso 1	Leve	8.0	9.42
		Moderado	4.4	41.12
		Agressivo	3.6	81.82
	Percurso 2	Leve	4.1	4.10
		Moderado	1.5	42.86
		Agressivo	2.7	72.93
Descritos em [24]	Percurso 1	Leve	11.5	13.55
		Moderado	11.5	76.16
		Agressivo	-	-
	Percurso 2	Leve	4.8	5.17
		Moderado	1.2	34.29
		Agressivo	-	-
Propostos	Percurso 1	Leve	5.5	6.48
		Moderado	3.2	29.91
		Agressivo	2.3	52.27
	Percurso 2	Leve	2.9	3.12
		Moderado	0.3	20.00
		Agressivo	2.2	59.46

4.3. Estimação baseada no *jerk*

A estimação do perfil de condução com base na classificação de dados de *jerk* é também realizada para cada amostra. Os valores de *jerk* são comparados com limiares previamente definidos para distinguir entre condução leve, moderada e agressiva. Valores de *jerk* reduzidos correspondem a transições suaves de aceleração, enquanto valores mais elevados indicam variações bruscas associadas a comportamentos de condução mais agressivos.

Nesta abordagem são utilizados os limiares de *jerk* definidos em [34], os quais são apresentados na Tabela 7, comparando-se os resultados obtidos da estimação com os dos percursos de referência.

Tabela 7 - Valores de *jerk* para classificação do perfil de condução segundo [34]

Perfil de condução	<i>jerk</i> [m/s ³]
Agressivo	[<-2] ou [>2]
Moderado	[-2 a -1] ou [1 a 2]
Leve	[0 a -1] ou [0 a 1]

A Figura 4-5 apresenta os histogramas que traduzem a estimação por classificação de dados de *jerk* levando em consideração os limiares propostos em [34] correspondentes aos percursos 1 e 2.




Figura 4-5 - Histogramas correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2

Quer para o percurso 1, quer para o percurso 2, os resultados da estimação dos perfis de condução obtidos, evidenciam uma correspondência significativa com o que era esperado,

ou seja, em comparação com as correspondentes anotações dos dois percursos de referência. Este facto pode ser constatado na Tabela 8, referente aos erros absolutos e percentuais.

Tabela 8 - Erros obtidos na estimação usando o *jerk*

Limiares utilizados	Tipo de Percurso	Perfil de Condução	Erro Absoluto	Erro Percentual (%)
Descritos em [34]	Percurso 1	Leve	2.8	3.30
		Moderado	2.1	19.36
		Agressivo	0.8	18.18
	Percurso 2	Leve	1.9	2.05
		Moderado	2.6	74.29
		Agressivo	0.8	21.62

4.4. Estimação baseada em aceleração e *jerk*

Após a análise individual dos resultados obtidos com base na aceleração e no *jerk*, entendeu-se relevante avaliar de que forma a combinação destas duas variáveis pode fornecer uma estimação mais completa e robusta do perfil de condução. A fusão das classificações de dados de aceleração e de *jerk* permite integrar simultaneamente a intensidade e as transições das variações de velocidade do veículo, o que não seria possível de alcançar sem os dois tipos de dados.

Neste trabalho, esta fusão foi feita para cada amostra. Caso a classificação individual dos dados (aceleração ou *jerk*) resulte em diferentes perfis, aplica-se uma regra de prioridade baseada na severidade do comportamento, considerando-se o perfil mais agressivo.

A Figura 4-6 apresenta os histogramas correspondentes à estimação dos perfis de condução resultantes da fusão das classificações individuais dos dados de aceleração e de *jerk*, para os dois percursos de referência.




Figura 4-6 - Histogramas correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2

Com base nos erros calculados entre os histogramas dos dois percursos de referência e os histogramas obtidos neste caso, Tabela 9, pode ser concluído que esta forma de estimação, envolvendo a fusão da classificação individual dos dados de aceleração e de *jerk*, é bastante aceitável, sendo evidente que os resultados da estimação conducente ao perfil agressivo é o melhor por originar comparativamente erros nulos ou muito baixos.

Tabela 9 - Erros obtidos na estimação usando a aceleração e *jerk*

Limiares utilizados	Tipo de Percurso	Perfil de Condução	Erro Absoluto	Erro Percentual (%)
Descritos em [34]	Percurso 1	Leve	1.8	2.12
		Moderado	1.8	16.82
		Agressivo	0	0
	Percurso 2	Leve	3.4	3.66
		Moderado	3.2	91.43
		Agressivo	0.2	2.70

4.5. Estimação baseada na velocidade de rotação do motor e *jerk*

Neste subcapítulo é abordada e testada a estimacões de perfis de condução baseada na fusão das classificações individuais dos dados de VRM e do *jerk*. A combinação destas duas variáveis permite integrar simultaneamente as transições de aceleração longitudinal do veículo e os esforços impostos ao motor na forma da sua VRM.

A estimação do perfil de condução, envolvendo a análise combinada do *jerk* e da VRM, é realizada através de zonas delimitadas no plano VRM-*jerk*. Cada região mapeia um perfil

específico: leve, caracterizado por baixos valores de VRM e reduzida variação de aceleração; moderado, associado a transições intermédias ou valores de VRM moderadamente elevados; agressivo, definido por uma VRM muito elevada ou variações de *jerk* intensas.

Para esse mapeamento têm de ser levados em consideração limiares de valores apropriados. Para o *jerk*, consideram-se os apresentados na Tabela 7. Para a VRM foram definidos empiricamente os respetivos limiares de valores, Tabela 10, uma vez que não foram encontrados na literatura.

Tabela 10 - Limiares definidos para a velocidade de rotação do motor

Perfil de condução	Velocidade de rotação do motor (rpm)
Leve	[0 a 2200]
Moderado	[2200 a 2500]
Agressivo	[<2500]

Na Figura 4-7 são apresentados dois gráficos, um para cada percurso, cada um deles apresentando três zonas coloridas no plano VRM-*jerk*, representando os perfis, correspondentes às interseções dos limiares associados a cada variável. Neste caso, as zonas correspondentes aos perfis leve, moderado e agressivo são representadas com cor verde, amarelo e vermelho, respetivamente. Adicionalmente, nos dois gráficos, estão representados pontos correspondentes a pares de valores instantâneos de VRM e *jerk*. Pela densidade visível destes pontos, é facilmente observável que os perfis de condução em ambos os percursos foram leves.




Figura 4-7 - Gráfico VRM-*jerk* correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2

Adicionalmente, os correspondentes histogramas, são os que se podem ver na Figura 4-8. Também se pode concluir que o perfil dominante é o leve.




Figura 4-8 - Histogramas correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2

Quanto aos erros, estes podem ser vistos na Tabela 11. De um modo geral, a estimação de perfis de condução envolvendo a fusão das classificações individuais dos dados de VRM e *jerk* tem validade bem aceitável na medida em que os erros são globalmente todos reduzidos, excetuando os relativos ao perfil moderado no percurso 2.

Tabela 11 - Erros obtidos na estimação usando a velocidade de rotação do motor e *jerk*

Limiares utilizados	Tipo de Percurso	Perfil de Condução	Erro Absoluto	Erro Percentual (%)
Propostos	Percurso 1	Leve	0.3	0.35
		Moderado	0.5	4.67
		Agressivo	0.2	4.55
	Percurso 2	Leve	4.0	4.31
		Moderado	3.8	108.57
		Agressivo	0.1	2.70

Inicialmente foi feita uma estimação dos perfis de condução baseada exclusivamente na classificação de dados de VRM. No entanto, verificou-se que a utilização isolada desta variável não permitia obter uma estimação fiável pois a VRM depende fortemente das características específicas de cada veículo, tais como a relação de caixa, o tipo de motor, o binário disponível, o regime de funcionamento ideal e até o estilo de condução habitual

associado ao próprio veículo. Deste modo, um mesmo perfil de condução pode corresponder a valores de VRM muito diferentes entre veículos distintos, o que inviabiliza a definição de limiares universais ou comparáveis. Por este motivo, a análise baseada exclusivamente na VRM não pode ser utilizada individualmente.

Contudo, quando a VRM é combinada com outra variável, no caso o *jerk*, o seu contributo torna-se significativamente mais relevante. A integração destas duas variáveis permite captar simultaneamente a resposta mecânica do motor e a intensidade das variações da aceleração longitudinal, resultando numa estimação mais robusta e sensível do comportamento de condução.

4.6. Estimação baseada na velocidade de rotação do motor e aceleração

Neste subcapítulo é abordada e testada a estimação de perfis de condução baseada na fusão das classificações individuais dos dados de VRM e da aceleração longitudinal do veículo. A combinação destas duas variáveis permite integrar simultaneamente as transições de velocidade do veículo e os esforços impostos ao motor na forma da sua VRM.

A classificação do perfil de condução, envolvendo a análise combinada da aceleração longitudinal e da VRM, é realizada através de zonas delimitadas no plano VRM-aceleração. Cada região mapeia um perfil específico, levando em consideração a combinação dos limiares apresentados na Tabela 5, para a aceleração, e na Tabela 10 para a VRM. Assim, a condução leve ocorre em situações de baixa VRM e acelerações reduzidas, a condução moderada surge em transições intermédias ou valores de VRM moderadamente elevados, e a condução agressiva está associada a valores elevados de VRM ou a valores de aceleração intensos, tanto positivos como negativos.

As representações gráficas no plano VRM-aceleração correspondentes à estimação dos perfis de condução ao longo dos dois percursos de referência são apresentados na Figura 4-9. Tal como no caso da fusão VRM-*jerk*, os perfis de condução leve, moderado e agressivo têm como cores correspondentes o verde, amarelo e vermelho, respetivamente. Analogamente, também, cada par de valores de VRM e aceleração adquiridos ao longo dos percursos corresponde a um ponto nesses gráficos, permitindo observar-se que a maior densidade de pontos se enquadra na região correspondente ao perfil leve em ambos os percursos.




Figura 4-9 - Gráfico VRM-aceleração correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2

Os histogramas da Figura 4-8 permitem quantificar as vezes que o condutor assumiu os diferentes perfis de condução ao longo dos dois percursos de referência.




Figura 4-10 - Histogramas correspondentes aos dois percursos de referência: a) percurso 1 e b) percurso 2

Quanto aos erros, estes encontram-se apresentados na Tabela 12. Os valores obtidos não são tão reduzidos quanto os que se obtiveram com a combinação de outras variáveis, nomeadamente nos casos de perfis tendencialmente mais agressivos. Porém, considera-se haver viabilidade nesta abordagem, captando tendências relevantes do comportamento de um condutor, embora com margem para melhorias, por exemplo ao nível do ajuste de limiares a serem considerados.

Tabela 12 - Erros obtidos na estimação usando a velocidade de rotação do motor e a aceleração

Limiares utilizados	Tipo de Percurso	Perfil de Condução	Erro Absoluto	Erro Percentual (%)
Propostos	Percurso 1	Leve	2.7	3.18
		Moderado	1.7	15.89
		Agressivo	1.0	22.73
	Percurso 2	Leve	1.1	1.18
		Moderado	0.1	2.86
		Agressivo	1.2	32.43

4.7.Considerações finais

Para comparar o desempenho global do método de estimação por classificação heurística de dados apresentado nos subcapítulos anteriores, procedeu-se inicialmente ao cálculo da média dos erros absolutos correspondentes aos três perfis de condução (leve, moderado e agressivo) para cada percurso de referência, Tabela 13.

Tabela 13 - Média do erro absoluto dos resultados dos percursos de referência

Variáveis	Médias dos erros absolutos	
	Percurso 1	Percurso 2
Aceleração	3.67	1.80
<i>jerk</i>	1.90	1.77
Aceleração e <i>jerk</i>	1.20	2.23
VRM e <i>jerk</i>	0.33	2.63
VRM e aceleração	1.80	0.80

De acordo com estes erros, uma mesma abordagem pode ser boa para um percurso de referência e não tão bom para o outro. Para se obter uma quantificação global considerou-se um erro total como sendo a soma das médias dos erros absolutos correspondentes aos dois percursos de referência, para cada abordagem, Tabela 14.

Tabela 14 - Erro total das abordagens

Variáveis	Erro total
Aceleração	5.48
<i>jerk</i>	3.68
Aceleração e <i>jerk</i>	3.44
VRM e <i>jerk</i>	2.96
VRM e aceleração	2.60

Como conclusão geral, a estimação baseada na combinação entre a VRM e a aceleração foi aquela que apresentou o menor valor do erro total. Com um erro total de 2.6, esta abordagem demonstrou a maior capacidade de distinguir corretamente os três perfis de condução, revelando-se aquela que origina resultados mais próximos dos correspondentes aos percursos de referência.

A integração simultânea da VRM e da aceleração permite captar de forma complementar tanto o esforço imposto ao motor como a intensidade das variações longitudinais, resultando numa caracterização mais sensível e fiável do comportamento de condução.

Deste modo, e tendo em consideração o desempenho superior demonstrado, esta abordagem, combinando a VRM-aceleração, foi a selecionada para a estimação dos perfis de condução no âmbito deste trabalho.

5. Aplicação do método e apresentação de resultados

Este capítulo apresenta os resultados da aplicação do método de estimação de perfis de condução em percursos realizados em ambiente real, resultante da combinação da VRM e da aceleração do veículo. No Capítulo 4, foi demonstrado que esta combinação é a melhor entre as diferentes variantes estudadas.

O método desenvolvido disponibiliza a estimação dos perfis de condução no final de um percurso, através da apresentação de um histograma com a percentagem associada a cada perfil. Adicionalmente, possibilita a estimação dos perfis de condução em cada instante, bem como o seu mapeamento geográfico ao longo do percurso, permitindo observar a evolução do comportamento do condutor.

As coordenadas geográficas dos percursos efetuados foram adquiridas pela aplicação para *smartphone* Sensor Logger, que regista de forma contínua os valores de latitude e longitude. Estes dados foram utilizados de forma a associar o perfil de condução a uma posição geográfica e possibilitar a representação dos perfis de condução ao longo do mapa do percurso.

Para avaliar o desempenho do método em diferentes condições de circulação, analisaram-se os percursos entre Alcobaça e Caldas da Rainha e em Alcobaça.

A Figura 5-1 apresenta a distribuição dos perfis de condução identificados pelo método no final do percurso entre Alcobaça e Caldas da Rainha. Neste percurso, verifica-se que o perfil leve é claramente dominante, refletindo um comportamento de condução suave na maior parte do percurso. Os perfis moderado e agressivo surgem com menor frequência, estando associados a momentos pontuais de aceleração, travagem ou variação brusca de velocidade.

A Figura 5-2 ilustra a evolução do perfil de condução ao longo do tempo, em intervalos de um segundo, numa duração total de 27 minutos. Para cada instante é apresentado o perfil de condução estimado, leve a cor verde, moderado a cor amarela e agressivo a cor vermelha. A representação gráfica evidencia a variabilidade temporal do perfil de condução, permitindo identificar mudanças de comportamento ao longo do tempo.

A Figura 5-3 ilustra a correspondente evolução do perfil de condução no mapa do percurso, usando a mesma codificação por cores, evidenciando a distribuição espacial do comportamento do condutor.




Figura 5-1 - Distribuição dos perfis de condução no percurso entre Alcobaça e Caldas da Rainha




Figura 5-2 – Evolução temporal do perfil de condução no percurso entre Alcobaça e Caldas da Rainha



Figura 5-3 - Mapa com os perfis de condução ao longo do percurso entre Alcobaça e Caldas da Rainha

A Figura 5-4 apresenta, de forma similar, a distribuição dos perfis de condução identificados pelo método no final do percurso em Alcobaça. Ao contrário do observado no percurso entre Alcobaça e Caldas da Rainha, este percurso revela uma maior presença de perfis moderado e agressivo, que em conjunto representam uma parcela significativa das ocorrências totais. Embora o perfil leve continue a surgir com maior frequência relativa, a proporção de comportamentos moderados e agressivos é substancial, evidenciando um estilo de condução mais dinâmico e marcado por variações rápidas de velocidade, acelerações intensas e momentos de maior exigência do motor. Este padrão sugere que o percurso inclui zonas onde o condutor necessitou de realizar manobras mais bruscas, como ultrapassagens, mudanças de velocidade, aproximação a interseções ou resposta a condições variáveis do tráfego.




Figura 5-4 - Distribuição dos perfis de condução no percurso em Alcobaça

A evolução do perfil de condução ao longo do tempo e no mapa do percurso, pode ser constatada na Figura 5-5 e Figura 5-6, respetivamente.

De forma global, os resultados apresentados demonstram que o método desenvolvido é eficaz na estimação e representação dos perfis de condução, constituindo uma base sólida para futuros desenvolvimentos, como a integração de dados contextuais, a adaptação dinâmica dos limiares das variáveis consideradas e a aplicação a diferentes tipos de veículos.




Figura 5-5 - Evolução temporal do perfil de condução no percurso em Alcobaça




Figura 5-6 - Mapa com os perfis de condução ao longo do percurso em Alcobaça

6. Conclusões e trabalho futuro

Este trabalho de projeto de mestrado descreve o desenvolvimento de um sistema de aquisição e registo de dados para serem classificados com o objetivo de se estimarem perfis de condução de veículos automóveis. A abordagem para a estimação combinando limiares de aceleração e de velocidade de rotação do motor foi a que apresentou melhores resultados nos percursos de referência utilizados no processo de validação, comparativamente a outras abordagens testadas, envolvendo a utilização de outras variáveis do veículo. Esta abordagem foi a que apresentou um menor erro total, calculado pela soma das médias dos erros absolutos originados por cada abordagem relativamente aos dois percursos de referência.

Os resultados da estimação foram apresentados sobre a forma de histogramas quantificando as ocorrências dos perfis, leve, moderado e agressivo, no final do percurso proporcionando uma informação global do comportamento do condutor. Adicionalmente, foram apresentadas as evoluções temporal e espacial dos perfis, proporcionando uma análise mais pontual.

Em síntese, a solução desenvolvida revelou-se funcional, fiável e adequada à estimação de perfis de condução, constituindo uma base sólida para aplicações práticas, como a gestão de frotas e empresas de aluguer de veículos. Apesar das limitações associadas à utilização de limiares fixos e à dependência do tipo de veículo (motor diesel), os resultados obtidos demonstram que a abordagem adotada é válida e eficaz.

O trabalho desenvolvido e os resultados alcançados abrem perspectivas para novas linhas de investigação e desenvolvimento que poderão ser exploradas em trabalhos futuros. Ao nível da aquisição de dados, será relevante considerar a integração de informação fisiológica do condutor, como a frequência cardíaca e o estado de fadiga, bem como dados contextuais, tais como tráfego, condições meteorológicas e tipo de via, e ainda outras variáveis associadas ao veículo, como a aceleração transversal e inclinação longitudinal. Adicionalmente, a aplicação de técnicas de aprendizagem automática para a estimação do perfil de condução, recorrendo a modelos treinados com bases de dados anotadas, poderá permitir ultrapassar as limitações inerentes aos critérios de decisão assentes em limiares fixos. No plano experimental, considera-se igualmente pertinente a extensão dos ensaios a diferentes tipologias de veículos automóveis, nomeadamente veículos elétricos, híbridos e movidos a

gasolina, bem como o aumento do número de percursos e de condutores, de forma a tornar a solução mais abrangente.

Referências bibliográficas

- [1] S.-H. Chen, J.-S. Pan, and K. Lu, “Driving Behavior Analysis Based on Vehicle OBD Information and AdaBoost Algorithms,” *Lecture Notes in Engineering and Computer Science*, vol. 1, pp. 102–106, Jan. 2015.
- [2] Y. Freund and R. E. Schapire, “Experiments with a New Boosting Algorithm,” 1996. [Online]. Available: <http://www.research.att.com/orgs/ssr/people/yoav,schapire/>
- [3] B. S. Dangra, M. V Bedekar, and S. S. Panicker, “Automotive User Profiling Using Vehicle Data Considering Different Driving Scenarios.” [Online]. Available: www.ijcsit.com
- [4] V. Lakomski, “Driver Pattern Clustering and Similarity Analysis Using Driving Simulation Data,” Jun. 2023.
- [5] J. A. Hartigan and M. A. Wong, “Algorithm AS 136: A K-Means Clustering Algorithm,” 1979.
- [6] Wilson Borba da Rocha Neto and José Maria Pires de Menezes Júnior, “Perfil de condução de motoristas: análise por meio de algoritmos de reconhecimento de padrões,” in *Proceedings XXII Congresso Brasileiro de Automática*, SBA Sociedade Brasileira de Automática, 2018. doi: 10.20906/cps/cba2018-1321.
- [7] J. M. Keller, M. R. Gray, and J. A. Givens, “A Fuzzy Δ -Nearest Neighbor Algorithm.”
- [8] G. Bin Huang, Q. Y. Zhu, and C. K. Siew, “Extreme learning machine: Theory and applications,” *Neurocomputing*, vol. 70, no. 1–3, pp. 489–501, Dec. 2006, doi: 10.1016/j.neucom.2005.12.126.
- [9] Navneeth, Prithvil, Sri Hari, Thushar, and M. Rajeswari, “On-Board Diagnostics and Driver Profiling,” *International Research Journal of Engineering and Technology*, 2020, [Online]. Available: www.irjet.net
- [10] Cleovano Gonçalves Batista, Thomaz Barros de Carvalho Prado, Júlio César Chaves Câmara, and Lilian Lefol Nani Guarieiro, “Influence of the Driver Profile on the Autonomy of Electric Vehicles,” *Journal of Bioengineering, Technologies and Health*, vol. 5, no. 2, pp. 106–110, May 2022, doi: 10.34178/jbth.v5i2.207.
- [11] K. Uvarov and A. Ponomarev, “Driver identification with OBD-II public data,” in *Conference of Open Innovation Association, FRUCT*, IEEE Computer Society, Jan. 2021. doi: 10.23919/FRUCT50888.2021.9347648.

- [12] J. C. Platt, “Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines,” 1998.
- [13] M. A. Friedl and C. E. Brodleyf, “Decision Tree Classification of Land Cover from Remotely Sensed Data.”
- [14] T. Kam Ho, “Random Decision Forests.”
- [15] J. V Tu, “Advantages and Disadvantages of Using Artificial Neural Networks versus Logistic Regression for Predicting Medical Outcomes,” 1996.
- [16] J. F. Júnior *et al.*, “Driver behavior profiling: An investigation with different smartphone sensors and machine learning,” *PLoS One*, vol. 12, no. 4, Apr. 2017, doi: 10.1371/journal.pone.0174959.
- [17] H. A. Ameen, A. K. Mahamad, S. Saon, M. A. Ahmadon, and S. Yamaguchi, “Driving behaviour identification based on OBD speed and GPS data analysis,” *Advances in Science, Technology and Engineering Systems*, vol. 6, no. 1, pp. 550–569, 2021, doi: 10.25046/aj060160.
- [18] S. N. Abdulwahid, M. A. Mahmoud, N. Ibrahim, B. B. Zaidan, and H. A. Ameen, “Modeling Motorcyclists’ Aggressive Driving Behavior Using Computational and Statistical Analysis of Real-Time Driving Data to Improve Road Safety and Reduce Accidents,” *Int. J. Environ. Res. Public Health*, vol. 19, no. 13, Jul. 2022, doi: 10.3390/ijerph19137704.
- [19] F. K. Adamidis, E. G. Mantouka, and E. I. Vlahogianni, “Effects of controlling aggressive driving behavior on network-wide traffic flow and emissions,” *International Journal of Transportation Science and Technology*, vol. 9, no. 3, pp. 263–276, Sep. 2020, doi: 10.1016/j.ijtst.2020.05.003.
- [20] M. G. Jasinski and F. Baldo, *A Method to Identify Aggressive Driver Behaviour Based on Enriched GPS Data Analysis*.
- [21] M. Ester, H.-P. Kriegel, J. Sander, and X. Xu, “A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise,” 1996. [Online]. Available: www.aaai.org
- [22] D. I. Tselentis and E. Papadimitriou, “Machine learning approaches exploring the optimal number of driver profiles based on naturalistic driving data,” *Transp. Res. Interdiscip. Perspect.*, vol. 21, Sep. 2023, doi: 10.1016/j.trip.2023.100900.
- [23] J. P. S. Gonçalves, “Obtenção de perfis de condução através de dados provenientes da rede CAN do veículo,” Universidade de Évora, 2024. [Online]. Available: <http://dspace.uevora.pt/rdpc/handle/10174/37191>
- [24] K. A. De, Z. Karunathilaka, and H. M. N. Dilum Bandara, “Driver Behavior Analysis using Vehicular Data Project Group 15 Supervised by,” 2017.

- [25] J. Xiang, O. Ghaffarpasand, and F. D. Pope, “Mapping urban mobility using vehicle telematics to understand driving behaviour,” *Sci. Rep.*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-53717-6.
- [26] L. Miguel Pinto Loureiro, D. André Ribeiro Lourenço Doutor Artur Jorge Ferreira Júri, D. Tiago Miguel Braga da Silva Dias Vogais, and D. Paulo Manuel Trigo Cândido da Silva Doutor André Ribeiro Lourenço, “INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA Driver Profile Classification,” 2023.
- [27] J. A. Bilmes, “A Gentle Tutorial of the EM Algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models,” 1998.
- [28] T. H. Itkonen, J. Pekkanen, O. Lappi, I. Kosonen, T. Luttinen, and H. Summala, “Trade-off between jerk and time headway as an indicator of driving style,” *PLoS One*, vol. 12, no. 10, Oct. 2017, doi: 10.1371/journal.pone.0185856.
- [29] . IEEE Staff, *2009 IEEE Workshop on Computational Intelligence in Vehicles and Vehicular Systems*. I E E E, 2009.
- [30] D. I. Tselentis and E. Papadimitriou, “Driver Profile and Driving Pattern Recognition for Road Safety Assessment: Main Challenges and Future Directions,” *IEEE Open Journal of Intelligent Transportation Systems*, vol. 4, pp. 83–100, 2023, doi: 10.1109/OJITS.2023.3237177.
- [31] D. J. Berndt and J. Clifford, “Using dynamic time warping to find patterns in time series,” in *Proceedings of the 3rd International Conference on Knowledge Discovery and Data Mining*, in AAAIWS’94. AAAI Press, 1994, pp. 359–370.
- [32] S. Hochreiter and J. “ Jürgen Schmidhuber, “Long Short-Term Memory.”
- [33] F. A. Gers, J. “ Jürgen Schmidhuber, and F. Cummins, “Learning to Forget: Continual Prediction with LSTM.”
- [34] H. Bellem, B. Thiel, M. Schrauf, and J. F. Krems, “Comfort in automated driving: An analysis of preferences for different automated driving styles and their dependence on personality traits,” *Transp. Res. Part F Traffic Psychol. Behav.*, vol. 55, pp. 90–100, May 2018, doi: 10.1016/j.trf.2018.02.036.

Anexo

Guia de utilização do sistema de aquisição e registo de dados

Para utilizar o sistema de aquisição desenvolvido para a estimação dos perfis de condução, é necessário criar previamente um ficheiro no formato CSV e guardá-lo no cartão de memória microSD. Após preparar o cartão, este deve ser inserido no respetivo leitor do sistema.

De seguida, procede-se à alimentação do dispositivo através de um cabo USB tipo A para micro USB, ligando-o a uma porta USB tipo A disponível no veículo. Caso o veículo não disponha desta porta, poderá ser utilizado um conversor de 12 V para 5 V adequado à tomada de isqueiro. É importante garantir que, após desligar o veículo, o sistema também se desliga automaticamente, evitando o consumo prolongado da bateria interna.

Concluída esta etapa, deve ligar a ficha de comunicação à entrada correspondente na caixa do projeto. Por fim, localize o conector OBD-II do veículo e conecte o cabo de comunicação do sistema, estabelecendo assim a ligação necessária para a recolha dos dados.

Nas Figuras 1 e 2, são apresentados, respetivamente, o local do conector OBD-II do veículo utilizado nos testes, bem como um esquema ilustrativo das localizações típicas desta ficha. Para facilitar a sua identificação, recomenda-se a consulta do manual do veículo, onde é normalmente indicada a posição exata do conector OBD-II.

Para iniciar o processo de aquisição de dados deverá pressionar o botão na tampa superior e aguardar que o LED acenda com a cor verde, para terminar a aquisição de dados deverá de voltar a pressionar o botão e aguardar que o LED verde apague.



Figura 1 – Localização do conector OBD-II no veículo de teste




Figura 2 – Localizações típicas do conector OBD-II