

Escola Superior de Tecnologia de Tomar

Deteção de Comportamentos de Risco de Condutores Utilizando Redes Neurais Recorrentes

Dissertação de Mestrado

Jorge Manuel da Silva Valente

Mestrado em Analítica e Inteligência Organizacional

Tecnologias de Informação e Comunicação

Tomar . Novembro . 2023



Escola Superior de Tecnologia de Tomar

Deteção de Comportamentos de Risco de Condutores Utilizando Redes Neurais Recorrentes

Dissertação de Mestrado

Jorge Manuel da Silva Valente

Orientado por:

Professora Doutora Sandra Maria Gonçalves Vilas Boas Jardim - Instituto Politécnico de
Tomar

Júri

Professor Adjunto Henrique Carlos dos Santos Mora
Professor Adjunto Fernando Sérgio Hortas Rodrigues (Arguente)
Professora Adjunta Sandra Maria Gonçalves de Vilas Boas Jardim

*Dissertação apresentada ao Instituto Politécnico de Tomar para cumprimento dos requisitos
necessários à obtenção do grau de Mestre em Analítica e Inteligência Organizacional*

*Dedico este trabalho à minha mãe, irmãos
e a todos aqueles que estiveram presentes
ao longo de todo este percurso*

Agradecimentos

A minha enorme apreciação a todos aqueles que contribuíram e influenciaram de alguma forma durante o meu percurso académico. Foi uma longa, árdua e intensa viagem, que não poderia ser feita sem a ajuda de todos, e à qual irei agora acrescentar mais uma etapa.

Um obrigado em especial à minha família, por todos os sacrifícios que fizeram ao longo de toda a minha vida, assim como pela confiança em mim depositada. Em especial á minha mãe, por todos os dificuldades e desafios que enfrentou ao longo das últimas décadas, e de todos os sacrifícios que teve de fazer.

Gostaria de agradecer à Professora Sandra Maria Gonçalves Vilas Boas Jardim, pela sua fulcral orientação, por todo o apoio e disponibilidade que demonstrou durante todo este processo, assim como pela sua enorme compreensão.

Um agradecimento também ao Professor Carlos Mora, pela orientação e apoio que sempre me prestou durante todo este trajeto, e na própria decisão de frequentar este mestrado.

Aos meus colegas Cláudia Ramalho e Tiago Vinha, por toda a ajuda na fase inicial deste projeto, assim como pelo tempo, apoio e amizade que me dedicaram ao longo de todo o mestrado.

E, finalmente, não posso deixar de agradecer ao Instituto Politécnico de Tomar por todo o apoio prestado ao longo desta fase académica e pela oportunidade de concluir mais uma importante fase no meu percurso como aluno. Não será, sem dúvida, o final do meu processo de aprendizagem por estas temáticas, mas constitui uma base essencial que levarei em diante, no meu restante percurso profissional.

Um grande obrigado a todos!

Resumo

Os acidentes rodoviários continuam a ser um problema global preocupante, que tem persistido nas últimas décadas. Uma resolução nas Nações Unidas de 2010 definia como objetivo, para a década de 2010-19, a redução das mortes na estrada em 50%, mas o valor atingido foi de apenas 8%. Embora a segurança rodoviária seja um tema complexo e multifacetado, a adoção de comportamentos de risco e os erros de natureza humana continuam a ser um dos principais fatores para os acidentes rodoviários. Um dos tópicos que tem suscitado grande interesse na comunidade científica é a classificação de perfis de condutores, particularmente em projetos de investigação que utilizam técnicas de aprendizagem automática (Machine Learning). Os objetivos para este projeto envolviam melhorar um sistema desenvolvido no ano anterior que recolhe dados de sensores de telemóvel e dados reais de condução para classificar os comportamentos do condutor. Os novos dados seriam utilizados para desenvolver um modelo de aprendizagem profunda (Deep Learning) que permitisse identificar e prever a ocorrência de comportamentos de risco. O modelo utilizado, designado por Long Short-Term Memory, pertence ao conjunto de redes neuronais recorrentes e tem demonstrado um potencial elevado na análise de dados de natureza sequencial no espaço e no tempo. Os resultados obtidos indicam um valor aproximado de precisão de 94%, o que parece indicar performance melhorada, face aos modelos testados anteriormente.

Palavras-chave: Inteligência Artificial; Sistemas de transporte inteligentes; Redes Neuronais Recorrentes; Comportamento de condutores; Segurança Rodoviária.

Abstract

Traffic accidents continue to be a global problem that has persisted over the past decades. A United Nations resolution from 2010 established an objective of reducing the number of road deaths by 50%, during the following decade, but the data obtained revealed a decrease of only 8%. Although driving safety is a complex and multi-faceted issue, risky behaviors and human error continue to be major contributors to traffic crashes. Establishing driver's profiles and detecting risky behaviors has been an increasingly researched topic amongst the scientific community, particularly when using Machine Learning models. The goal of this study was to improve a pre-existing framework that was developed last year, which used mobile phones sensors and environment data to establish a driving profile and access risky behaviors. Additionally, with the improved framework, new driving data was to be collected and used to train a Deep Learning model that could predict and alert the driver when it is exhibiting dangerous behaviors. The selected DL model is known as Long Short-Term Memory, which uses a Recurrent Neural Network (RNN) that has shown promising results when handling sequential data, as described in the existing literature. The obtained model produced results with approximately 94% precision, when classifying driving patterns, which indicates increased performance against previously tested methods.

Keywords: Artificial Intelligence; Intelligent Transportation Systems (ITS); Recurrent Neural Networks; Driver behavior; Road Safety

Índice

Agradecimentos	vi
Resumo	vii
Abstract.....	viii
Índice	ix
Índice de Figuras	x
Índice de Tabelas	xi
Lista de Abreviaturas.....	xii
1. Introdução.....	13
1.1 Contextualização temática	13
1.2 Objetivos do projeto.....	16
1.3 Estrutura do relatório	17
2. Enquadramento teórico e estado de arte.....	18
2.1 Inteligência Artificial e <i>Machine Learning</i>	18
2.2 Classificação de perfis de condução	21
2.3 Modelo de redes <i>LSTM</i>	26
3. Materiais e Métodos	29
3.1 Planeamento do projeto	29
3.2 Aplicação Android.....	31
3.3 Recolha de dados	32
3.4 Processamento de dados	34
3.5 Modelo de LSTM.....	36
4. Resultados	38
5. Discussão.....	42
6. Conclusões	44
Bibliografia.....	45

Índice de Figuras

Figura 1 - Mortes em 2019 devido a acidentes rodoviários por cada 100000 habitantes, dividido por grupos etários, segundo o ITF (ITF, 2022).	14
Figura 2 – Dados sobre acidentes de viação em Portugal Continental com o número de vítimas, feridos e mortos. Recolhido a Outubro de 2023, segundo a Pordata (Pordata, 2023).	15
Figura 3 – Esquema de funcionamento de uma rede do tipo <i>Long-Short Term Memory</i> (LSTM). Adaptado de Olah (2015).	28
Figura 4 - Estrutura global de dados e relações entre as diversas tabelas.	30
Figura 5 – Imagens de alguns dos diferentes ecrãs da aplicação de android..	32
Figura 6 – Evolução das métricas de treino do modelo inicial.....	38
Figura 7 – Resultado dos testes de previsão de comportamentos.	39
Figura 8 – Gráfico de comparação das percentagens de precisão obtidas para diferentes comparações de parâmetros.....	40
Figura 9 – Gráficos de comparação das matrizes de confusão para diferentes comparações de parâmetros.....	41

Índice de Tabelas

Tabela 1 - Métodos de ML utilizados em problemas de análise e classificação de comportamentos de condutores rodoviários.	24
Tabela 2 - Tabela com as características do conjunto de dados utilizado para análise e construção dos modelos de ML.	34
Tabela 3 – Tabela com resumo dos resultados obtidos, durante as iterações aos parâmetros do modelo de LSTM..	39

Lista de Abreviaturas

- AI – *Artificial Intelligence* (Inteligência Artificial)
ML – *Machine Learning* (Aprendizagem Automática)
DL - *Deep learning* (Aprendizagem Profunda)
RL – *Reinforcement Learning* (Aprendizagem Reforçada)
DRL – *Deep Reinforcement Learning* (Aprendizagem Reforçada Profunda)
SVM – *Support Vector Machines* (Máquinas de Suporte de Vetores)
CNN – *Convolutional Neural Networks* (Rede Neuronal Convolucional)
RNN – *Recurrent Neural Network* (Rede Neuronal Recorrente (RNR))
LSTM - *Long Short-Term Memory* (Memória de Curto e Longo Prazo)
API – *Application Programming Interface* (Interface de Programação de Aplicações)
GPS – *Global Positioning System* (Sistema Global de Posicionamento)
ITF – *International Transportation Forum* (Fórum Internacional de Transportes)

1. Introdução

Neste capítulo serão apresentados os conceitos essenciais para o enquadramento do projeto, assim como as principais decisões tomadas e os pressupostos tidos em consideração, e como estas tiveram influência no projeto de investigação. No presente capítulo, é feito um breve enquadramento teórico das principais problemáticas utilizando algumas referências de suporte quando necessário. São apresentados e explicados os objetivos deste projeto, tendo como base as informações apresentadas. Por último, será detalhada a restante estrutura deste relatório, para facilitar a sua navegação e compreensão.

1.1 Contextualização temática

A proliferação de veículos de transporte tornou a sua utilização numa necessidade para muitas pessoas. No entanto, o aumento do número de condutores e da sua densidade nalgumas cidades levou a profundas alterações na gestão de tráfego nas últimas décadas (Mantouka and Vlahogianni, 2022). A pandemia de COVID-19 causou também um grande nível de disrupção nos hábitos de condução das pessoas (Fafoutellis *et al.*, 2023), sobretudo tendo em conta as restrições de movimentação implementadas por todo o mundo, e a duração em que se estenderam. A implicação das medidas de restrição nos hábitos dos condutores é um fator ainda não totalmente compreendido e que pode ter consequências importantes em matéria de segurança rodoviária. De facto, estudos referem uma mudança nos padrões de movimentação que favoreceram desproporcionalmente a utilização de viaturas pessoais (Lyon *et al.*, 2023; Fafoutellis *et al.*, 2023). Num estudo efetuado no Canada foi notado um aumento ligeiro da ocorrência de comportamentos de risco pelos condutores no período após o levantamento das restrições (Lyon *et al.*, 2023). Estas mudanças dos padrões de condução podem ser preocupantes, pois coincidem com o aumento do número de condutores nas estradas.

Segundo dados disponibilizados pela Organização Mundial de Saúde no ano 2021, o número de vítimas causadas por acidentes rodoviários ascende já a 1.3 milhões de mortos, e 50 milhões de feridos. Atualmente, um dos principais fatores de preocupação mundial em segurança rodoviária são os acidentes de viação. Segundo o ITF (Fórum Internacional de Transportes, 2022), embora o número de mortes por acidentes rodoviários tenha diminuído em 6% na população geral, durante o período entre 2010-2019, esta aumentou em cidadãos acima de 65 anos numa proporção semelhante (ITF, 2022). Em Portugal, durante o ano de 2019, os dados desta organização indicam que a

faixa etária com maior número de mortes por acidente rodoviário se situa entre os 21-24 anos (ITF, 2022), estando os dados completos representados na figura 1.




Figura 1 - Mortes em 2019 devido a acidentes rodoviários por cada 100000 habitantes, dividido por grupos etários, segundo o [ITF](#) (ITF, 2022).

Em Portugal, embora o número de vítimas tenha diminuído durante as duas últimas décadas (ver figura 2), continuam a existir diversos comportamentos de risco nas atitudes dos condutores, que por vezes têm consequências trágicas. Segundo dados da Pordata (2023), o número de mortos por acidentes de viação em 2022 foi de 462 indivíduos. Mesmo sendo este número bastante inferior ao pico registado em 1975 (de 2676 mortes), este vem em seguimento de uma descida acentuada, verificada durante o período da pandemia de COVID-19, tendo vindo a subir desde então, com o mínimo histórico de vítimas verificados em 2020 (ver figura 2).

Na última década alguns comportamentos de risco dos condutores têm vindo a crescer, com particular destaque para o uso de telemóveis durante a condução (Al-Rakhami *et al.*, 2021). O foco de alguns condutores está em terminar as viagens no menor tempo possível, o que leva à adoção de alguns comportamentos de risco (Singh *et al.*, 2017). Adicionalmente, existem diversos tipos de possíveis distrações, quer sejam visuais, motoras (o condutor interrompe contacto com o volante) ou cognitivas (o condutor não se foca na via de circulação), que podem potenciar a ocorrência de acidentes (Al-Rakhami *et al.*, 2021). O número de acidentes causados por erros humanos continua a ser preocupante, sobretudo considerando o desfecho mortal que estes podem ter.




Figura 2 – Dados sobre acidentes de viação em Portugal Continental com o número de vítimas, feridos e mortos. Recolhido a Outubro de 2023, segundo a [Pordata](#) (Pordata, 2023).

O processo de condução de um veículo envolve uma série de capacidades motoras e psicológicas do condutor, que têm como base características como a sua perceção, a capacidade operacional e o processo de tomada de decisões, entre outras. Dados como a idade, a experiência de condução (Elassad *et al.*, 2020), determinados problemas de saúde, stress e fadiga, entre outros, poderão ter influência na capacidade de condução de um indivíduo (Lattanzi and Freschi, 2021; Zhu *et al.*, 2018). Devido à grande variabilidade possível, é difícil estabelecer um perfil de condutor (Sagberg *et al.*, 2015), mesmo tendo como base o conjunto de características do condutor e as suas práticas de condução (Elassad *et al.*, 2020; Zhu *et al.*, 2018). Ainda assim, o comportamento dos condutores é referido como um dos fatores mais relevantes para a ocorrência de acidentes (Elassad *et al.*, 2020), o que explica a grande atenção que tem tido por parte da comunidade científica, nas últimas duas décadas.

Alguns sistemas de condução tiram já proveito de funcionalidades desenvolvidas por sistemas inteligentes, tirando proveito da muita investigação que tem sido realizada. Grupos de fabricantes automóveis como a Lexus, Mercedes, ou Volkswagen possuem já sistemas de deteção do estado de sonolência dos condutores, utilizando sensores que monitorizam a posição da cabeça do condutor (Zhu *et al.*, 2018). Uma outra aplicação popular destas ferramentas envolve o desenvolvimento de sistemas de condução autónomos (Li *et al.*, 2021; Farag, 2019), sistemas especializados de assistência e alguns sistemas de travagem de emergência autónomos, que já possuem um elevado grau de maturidade.

Outros estudos têm como base a simulação de padrões de condução, que permite obter uma grande quantidade de dados em regimes controlados (Al-Rakhami *et al.*, 2021; Naurois *et al.*, 2019; Zhu *et al.*, 2018). De facto, a comunidade científica tem-se desdobrado em tentativas para desenvolver diferentes métodos de classificação de perfis, de forma a desenvolver estratégias para prevenção de acidentes, poupança de combustível, conforto na condução, ou até mesmo na prevenção de furtos (Mantouka e Vlahogianni, 2022; Zhao *et al.*, 2022; Martinelli *et al.*, 2020).

Assim, de forma a melhorar a segurança rodoviária, é fundamental estudar o perfil dos condutores de forma a poder identificar e agir no sentido de reduzir os comportamentos de risco (Elassad *et al.*, 2020). Neste sentido, em agosto de 2020, a Assembleia Geral das Nações Unidas adotou a resolução 74/299 em que declara a década de 2021 a 2030 como a segunda década de ação para a segurança rodoviária. Nesta resolução, os países aderentes têm como responsabilidade desenhar estratégias de segurança rodoviária que levem a uma diminuição de pelo menos 50% no número de mortes e de lesões graves (International Transport Forum, 2022).

1.2 Objetivos do projeto

Tendo em conta o referido na seção anterior, o presente trabalho tem como objetivo a utilização de técnicas de Inteligência Artificial para deteção e classificação de comportamentos de risco por parte de condutores de veículos rodoviários. O objetivo geral é o desenvolvimento de um sistema intuitivo, e fácil de utilizar, que permita recolher dados de condução em tempo real, para posterior utilização no treino de modelos de Inteligência Artificial. O objetivo principal é a aplicação de modelos de Inteligência Artificial de forma a permitir classificar o perfil de risco dos condutores. Adicionalmente, foi ainda objetivo deste trabalho a classificação entre os vários tipos de comportamento de risco possíveis. Uma vez obtidos os modelos, é igualmente importante analisar o seu desempenho, de forma a tirar conclusões sobre a viabilidade dos métodos utilizados e comparar os resultados obtidos com os de outros projetos de investigação.

O trabalho desenvolvido permite definir um conjunto de bases que podem ser utilizadas para realizar estudos mais especializados. O impacto deste estudo poderá servir para definir estratégias de investigação futura, e poderá também ter impacto na tomada de decisões em matéria de segurança rodoviária.

1.3 Estrutura do relatório

As restantes secções deste relatório irão focar-se nos detalhes técnicos do trabalho realizado, assim como na discussão dos resultados. As restantes secções são:

- Em “**Enquadramento teórico e estado de arte**” é feita uma revisão geral dos temas e conceitos mais importantes para este estudo.
- No capítulo de “**Materiais e métodos**” serão explicados os procedimentos técnico-científicos com que o projeto foi concretizado, em todas as suas fases. Esta secção descreverá todo o processo, desde o desenho dos sistemas à recolha e análise dos dados obtidos;
- No capítulo de “**Resultados**” serão descritos os dados obtidos após a fase de recolha;
- Na “**Discussão**” serão analisados os dados obtidos e a qualidade dos modelos de IA obtidos. Serão propostas algumas hipóteses que justifiquem os resultados, identificando potenciais problemas encontrados.
- Por fim, no capítulo da **Conclusão** serão tiradas relações com base em todo o processo. Serão sugeridas soluções para os problemas encontrados e potenciais sugestões para futuros projetos de investigação.

2. Enquadramento teórico e estado de arte

No presente capítulo é realizada uma análise detalhada à investigação recente relacionada com o tema deste trabalho, assim como uma análise ao estado de arte e técnicas utilizadas pelos vários investigadores. Enquanto na secção anterior foram abordados os temas gerais, de uma forma mais superficial, na secção que se segue o objetivo é fornecer toda a informação necessária para que qualquer leitor consiga entender o que se encontra descrito no resto deste trabalho. Assim, o primeiro tema que tem de ser abordado refere-se aos conceitos que envolvem Inteligência Artificial, com particular enfoque na área *Machine Learning*.

2.1 Inteligência Artificial e *Machine Learning*

A Inteligência Artificial (IA) é uma disciplina que se enquadra na ciência de dados, e que tem como principal objetivo o desenvolvimento de programas ou sistemas informáticos capazes de realizar tarefas ligadas ao processamento e modelação de conjuntos de dados complexos (Raschka *et al.*, 2020). *Machine Learning* (ML) é uma área de IA, estudada desde os anos 50 (Elassad *et al.*, 2020), que se dedica ao desenvolvimento de modelos de analítica que conseguem “aprender” de forma rápida, através da análise de padrões em grandes conjuntos de dados (ou *datasets*). Uma característica particular dos modelos de aprendizagem atuais é que a sua conceção tem grande inspiração na forma de pensar dos cérebros humanos (Raschka *et al.*, 2020).

Uma das grandes vantagens em utilizar modelos de ML, é que estes possuem uma capacidade de analisar grandes quantidades de dados, e estabelecer relações entre características que podem não ser óbvias numa primeira observação. Adicionalmente, a utilização de algoritmos de aprendizagem permite também automatizar algumas tarefas de natureza complexa ou altamente repetitivas, assim como desenvolver sistemas que necessitem de uma mínima intervenção humana (Raschka *et al.*, 2020).

As técnicas de ML têm observado uma crescente popularidade nas últimas décadas, estando já presentes em muitos dos sistemas digitais que são usados pelo cidadão comum, no seu dia-a-dia (Singh *et al.*, 2022). Para isto tem igualmente contribuído a disseminação de instrumentos tecnológicos equipados com sensores dos mais variados tipos (Ghate e Hemalatha, 2023). Estes fatores, aliados à crescente capacidade de processamento e armazenamento de informação que tem ocorrido nas últimas décadas, levaram a que, atualmente, exista uma quantidade enorme de dados que são gerados e analisados continuamente. A enorme flexibilidade de métodos de ML existentes, fazem,

com que a sua presença seja cada vez mais disseminada, em muitas áreas de investigação e aplicações práticas que podem ir das ciências ambientais, finanças, saúde, sistemas informáticos, engenharias, entre muitas outras (Henrique *et al.*, 2023; Zhu *et al.*, 2022).

Os modelos de ML podem ser divididos em duas categorias: Modelos supervisionados e modelos não-supervisionados. A principal diferença entre ambos é que os modelos supervisionados são alimentados com objetos de dados etiquetados (classificados), tendo um determinado rótulo ou classe associado a cada objeto de dados (Pratap e Sardana, 2022). Assim, os modelos supervisionados são apropriados para problemas de regressão e de classificação de dados (Zhu *et al.*, 2022). Alguns autores argumentam que se deve considerar como uma terceira categoria os modelos de aprendizagem reforçada, ou *Reinforcement Learning* (RL) (Bansal *et al.*, 2022). Estes serão abordados mais à frente.

Um dos problemas encontrados com este tipo de técnicas, é que os modelos desenvolvidos tendem a apenas ser aplicáveis para a mesma estrutura de dados com que o modelo foi treinado, o que não permite extrapolações entre conjuntos de dados distintos, mesmo quando pretendem atingir objetivos semelhantes. Para além disso, não existe uma convenção universal que defina a utilização deste tipo de algoritmos, o que leva a que por vezes seja difícil encontrar o modelo mais indicado para uma nova aplicação que se pretende estudar (Elassad *et al.*, 2020). Ainda assim, a capacidade destes modelos em analisar e encontrar padrões em conjuntos de dados muito volumosos torna-os uma ferramenta essencial em muitas áreas de investigação.

Embora existam diversas linguagens de programação que podem ser utilizadas para desenvolver e treinar modelos de ML, na última década a linguagem *Python* tem beneficiado de uma grande disseminação dentro da comunidade científica. Alguns dos motivos para o aumento de popularidade desta linguagem em ciência de dados podem ser associados à quantidade de bibliotecas disponíveis, a fácil compreensão da sua sintaxe, e a sua flexibilidade (Raschka *et al.*, 2020).

Dependendo dos objetivos concretos do estudo e da estrutura de dados utilizada, muitos modelos de ML foram já testados e aplicados com diferentes graus de sucesso. A aplicação de técnicas e modelos de ML tem sido bastante diversificada, com aplicação tanto de modelos supervisionados como não-supervisionados (Lattanzi e Freschi, 2021). De uma forma geral, podemos considerar modelos que utilizam redes neuronais (modelos de *Deep Learning*) como sendo uma subcategoria de ML (Raschka *et al.*, 2020). Dentro do tema de investigação em que se enquadra o presente trabalho, alguns dos exemplos encontrados na literatura incluem a aplicação de modelos como Máquinas de Suporte de Vetores, Redes Neuronais Convolucionais, Modelos Markov, Modelos de Regressão Bayesianos, *Fuzzy Control Theory*, Redes Neuronais Profundas, Modelos de Aprendizagem Reforçada, entre outros (Mantouka and Vlahogianni, 2022; Zhao *et al.*,

2022; Al-Rakhami *et al.*, 2021; Li *et al.*, 2021; Shahverdy *et al.*, 2020; Zhu *et al.*, 2018; Chong *et al.*, 2013; Eren *et al.*, 2012).

Apesar dos grandes avanços que se têm verificado nesta área e da proliferação de novas técnicas e modelos na última década, a utilização de modelos tradicionais de ML continua a ser justificada em investigação (Raschka *et al.*, 2020). Preocupações com o direito à privacidade, limitações técnicas e de hardware, capacidade de recolha de dados limitada, entre outras, são razões legítimas que justificam a utilização de técnicas como as Máquinas de Suporte de Vetores (*Support Vector Machine* (SVM)), K-Vizinhos mais Próximos (*K-Nearest Neighbors* (KNN)), entre outras, para estudos de perfis de condução (Shahverdy *et al.*, 2020; Eren *et al.*, 2012). Uma outra vantagem deste tipo de técnicas é que possuem uma extensa base de investigação, sendo técnicas já muito estudadas, e com utilização prática numa grande amplitude de tópicos e temáticas.

A evolução das capacidades de processamento nos computadores modernos tem levado a uma maior popularidade da utilização de modelos de *Deep Learning* (DL) em estudos que envolvem análise de dados. Quando temos em conta a aplicação de modelos de DL, que tomam partido da aplicação de redes neuronais, podemos igualmente encontrar uma grande variedade de aplicações e modelos testados. Um tipo de modelo que poderá ser particularmente relevante para o estudo de perfis de condução são as Redes Neurais Recorrentes (*Recurrent Neural Networks* - RNN). Estes modelos de DL têm a particularidade de detetar padrões que ocorrem ao longo de pequenos intervalos temporais. De facto, alguns estudos (Morton *et al.*, 2016) mostraram resultados promissores utilizando modelos deste tipo, em particular, uma classe de modelos designados por LSTM (*Long Short-Term Memory* (LSTM)).

No que respeita a outras aplicações de DL, alguns estudos testaram inclusive a conversão de sinais de condução para imagens, utilizando técnicas como a “*recurrence plot technique*”, para conseguir utilizar Redes Neurais Convulsionais (*Convolutional Neural Networks* (CNN)) mais eficientemente (Shahverdy *et al.*, 2020). Um outro tipo de modelos de DL com possível aplicação neste tipo de estudos são as redes neuronais de alimentação direta (*feed-forward neural networks*). Mesmo considerando as referências à aplicação deste tipo de modelos em contextos similares ao do presente trabalho (Latanzi and Freschi, 2021; Morton *et al.*, 2016), não foi possível determinar as possíveis vantagens na utilização deste tipo de redes, em detrimento de outros modelos já referidos.

Dentro dos grupos de métodos utilizados, um foco recente de investigação tem sido dado para a aplicação de modelos de aprendizagem reforçada, quer isoladamente como em conjunto com técnicas de DL (*Deep Reinforcement Learning* – DRL) (Mantouka and Vlahogianni, 2022). A grande vantagem da utilização de modelos de RL centra-se no facto de estes terem como base os processos de decisão de Markov (*Markov Decision Process* - MDP), onde o objetivo é maximizar a geração de recompensas. Neste

tipo de processos, as interações entre um agente e o seu ambiente de treino são modeladas, sendo depois atribuídas recompensas diferentes às várias interações tomadas pelo agente. Assim, durante o treino do modelo, o agente é incentivado a tomar decisões que gerem a maior recompensa possível, durante o intervalo de tempo estabelecido. O desenvolvimento de algoritmos de *Deep Q Network* (DQN) potenciaram avanços significativos nesta área, pois permitiram desenvolver, de forma eficiente, modelos capazes de processar dados discretos que pertencem a espaços com reduzida dimensionalidade (Mantouka and Vlahogianni, 2022).

Uma das possíveis limitações dos modelos de RL para estudos de condução é que algumas das características, como a velocidade ou características temporais, possuem natureza contínua. Alguns autores desenvolveram soluções que endereçam este problema, através da aplicação de técnicas de discretização, como a aplicação de lógica difusa (*fuzzy logic*), que permite fazer o mapeamento e agrupamento de características contínuas, em grupos de características discretas (Chong *et al.*, 2013).

Com a popularidade atual deste tipo de técnicas, muitos estudos se têm dedicado a investigar a aplicação de modelos de ML para analisar o comportamento de condutores. Embora a atenção acrescida seja benéfica e positiva, a grande quantidade de nova investigação que é publicada torna o acompanhamento e validação das técnicas utilizadas cada vez mais difícil (Elassad *et al.*, 2020). , a quantidade de informação disponível é extremamente importante para contextualizar o problema e as soluções que foram encontradas até hoje. Na secção seguinte são apresentadas algumas das técnicas mais utilizadas neste tipo de problemas, e algumas das principais características e particularidades que têm sido relatadas pela comunidade científica.

2.2 Classificação de perfis de condução

Como anteriormente referido, tem havido recentemente um grande foco da comunidade científica na identificação e classificação de comportamentos de condução agressivos e arriscados. O tipo de sistemas que integram a recolha de dados para assistir na condução de viaturas são por vezes denominados como “Sistemas Inteligentes de Transporte” (*Intelligent Transportation Systems - ITS*) (Singh *et al.*, 2017). Dentro desta categoria, existem muitos estudos publicados que aplicam modelos de Inteligência Artificial para desenvolver estratégias de segurança rodoviária (Shahverdy *et al.*, 2020; Saleh *et al.*, 2017). Um problema apontado por alguns autores na aplicação de modelos de ML supervisionados é a dificuldade em estabelecer concretamente o que constitui um comportamento de risco (Lattanzi e Freschi, 2021). Esta secção tem por objetivo apresentar uma revisão do estado da arte nesta temática, dando principal ênfase a estudos científicos publicados nos últimos 6 anos.

Devido à grande quantidade de investigação disponível, não existe um consenso nalgumas definições ou no que respeita às técnicas e metodologias utilizadas para classificar comportamentos de condutor. Embora existam variações, uma forma geral de definir o comportamento de condução normal, ou seguro, envolve procurar situações que evitem riscos acrescidos (Shahverdy *et al.*, 2020). Num estudo de Yu *et al.*, (Yu *et al.*, 2017), os autores identificaram alguns comportamentos de risco como situações de viragens com elevada amplitude, condução aos zig-zags, travagens bruscas e mudanças de direção súbitas. Adicionalmente, uma parte considerável da literatura aplica deteção de classificação única, com apenas um tipo de comportamento de risco (Matousek *et al.*, 2019; Sabokrou *et al.*, 2018), havendo maior escassez de publicações que estudem vários comportamentos de risco em simultâneo (Shahverdy *et al.*, 2020; Yu *et al.*, 2017).

De forma a estruturar os métodos aplicados, alguns estudos optam por diferenciar entre duas classes de estratégias diferentes que podem ser usadas para classificar comportamentos de condutores (Saleh *et al.*, 2017):

- **Métodos de dinâmicas de veículos:** focam-se na utilização de dados de condução obtidos com base nos veículos. Estes podem incluir a utilização de giroscópios, acelerómetros, rotações por minuto (Lattanzi and Freschi, 2021; Shahverdy *et al.*, 2020), velocidade, aceleração, eventos de travagem, entre outros (Shahverdy *et al.*, 2020; Saleh *et al.*, 2017).
- **Métodos de dinâmicas de condutores:** focam-se na utilização de dados obtidos dentro da própria viatura, normalmente incluindo captação de imagens com câmaras. A informação obtida foca-se em características do próprio condutor, como movimentações faciais, postura, ou até mesmo a sua atividade cerebral utilizando sensores de *EEG* que possuem alta capacidade preditiva (Xiao *et al.*, 2022; Galarza *et al.*, 2018; Zhu *et al.*, 2018).

É possível encontrar bibliografia onde os autores estudam o comportamento do condutor isoladamente (Lattanzi and Freschi, 2021; Shahverdy *et al.*, 2020; Galarza *et al.*, 2018), mas também outros onde é aplicada uma lógica mais abrangente, onde é considerado não só o comportamento do condutor, mas também o estado do veículo e do ambiente (Al-Sultan *et al.*, 2013). Os métodos de dinâmicas de veículos podem ser adicionalmente subdivididos entre métodos que se focam na captação de dados de sensores internos da viatura (Lattanzi and Freschi, 2021) ou captando dados com sensores externos, como os de telemóveis. Das duas classes de métodos, os métodos de dinâmicas de veículos são mais frequentemente estudados pela comunidade científica, uma vez que permitem a utilização de uma vasta quantidade de sensores amplamente disponíveis (Saleh *et al.*, 2017).

Para além da diferenciação do tipo de dados recolhidos, podemos também fazer distinção de estudos pelo tipo de modelos de IA utilizados. Considerando a contextualização de alguns dos diferentes tipos de estratégias adotados por investigadores, são, de seguida, explorados em maior detalhe alguns dos trabalhos mais relevantes e recentes nesta área.

Num estudo bastante recente, Ma *et al.* (2023) focaram-se na deteção em tempo real de comportamentos de condução arriscados, utilizando para tal um modelo de *Long-short Term Memory* residual (LSTM-R). Os dados de cinemática foram recolhidos utilizando sensores de smartphone. A particularidade desta aplicação é que o modelo inclui um “algoritmo residual”, que é sensível a uma janela de tempo, e que é aplicado para permitir a deteção de comportamento anómalos em tempo real, tendo em conta a magnitude e continuidade dos valores residuais obtidos. Os autores fizeram também uma comparação dos resultados contra outros 5 modelos de ML. Após validação dos resultados, os autores concluíram que a performance do modelo LSTM-R foi significativamente superior a todos os restantes modelos testados, revelando boa capacidade de deteção num sistema que consideram como sendo de fácil utilização.

Xu *et al.* (Xu *et al.*, 2022), desenvolveram um método de predição de intenções por parte dos condutores. Nesta aplicação, os autores conciliaram a aplicação de um modelo de LSTM com um modelo de HMM (*Hidden Markov Model*) para tentar determinar quais as intenções dos condutores que dão origem a determinados comportamentos de risco. Para treinar os modelos, os autores utilizaram dados provenientes do *Shanghai Naturalistic Driving Study*. Os resultados obtidos indicaram uma boa performance do método desenvolvido, tendo igualmente validado melhorias da performance de previsão quando utilizados os modelos de LSTM e HMM de forma complementar.

Mantouka e Vlahogianni (2022) testaram a aplicação de modelos de DRL numa base de dados. O objetivo geral foi de treinar o modelo de DRL para tomar decisões otimizadas em ambientes de condução, utilizando os diferentes perfis de condutor que foram estabelecidos após a recolha de dados. A aplicação deste tipo de modelos tem benefícios únicos na sua capacidade de alcançar desempenhos próximos de humanos em tarefas complexas, através de repetições e interações com o ambiente de treino (Mantouka and Vlahogianni, 2022).

Utilizando uma base de dados pública, com informação relativa a mais de 26 horas de condução, Lattanzi e Freschi (2021) realizaram um estudo de classificação de comportamentos de condutores. Neste estudo foram utilizados dados de sensores internos das próprias viaturas, tendo sido testados dois modelos de *Machine Learning* distintos: Máquinas de Suporte de Vetores (SVM) e redes neuronais de “feed-forward”. Os dados dos autores indicaram valores de precisão acima de 90%, para ambos os modelos testados.

Em Naurois *et al.*, (2019), os autores aplicaram dois modelos de rede neuronal artificial para tentar prever a ocorrência de estados de incapacidade e sonolência no condutor, e classificar estes estados. Os seus resultados indicaram boa capacidade de previsão de estados de sonolência, conseguindo inclusive prever quando o condutor ficaria incapacitado, até 5 minutos antes da ocorrência. Adicionalmente, dentro dos modelos testados, o que obteve melhores resultados de deteção e previsão foi o modelo que consolidava os métodos de dinâmicas de condutores (análise de imagens e gestos) com informação dos tempos de condução.

Num estudo de 2017, Saleh *et al.*, (2017) utilizaram redes neurais recorrentes, do tipo LSTM, para traçar o perfil de condutores, utilizando dados recolhidos através de sensores de telemóvel. Uma particularidade do modelo criado pelos autores é a utilização de janelas temporais onde são obtidos vetores fundidos de características. Estas janelas temporais são utilizadas para classificar o comportamento do condutor utilizando 3 classes de comportamentos: normal, agressivo e sonolento. Ao método desenvolvido os autores denominaram modelo “LSTM empilhado” (*Stacked-LSTM*).

Em alguma da literatura analisada (Singh *et al.*, 2017; Elasad *et al.*, 2020; Mantouka *et al.*, 2022; Zaini *et al.*, 2023), os autores compilaram numa tabela a informação chave sobre a literatura consultada, identificando quais os métodos de recolha de dados utilizados, os modelos aplicados, que informação pretendiam determinar, e quais os principais problemas com as metodologias aplicadas. Sendo este tipo de estrutura de dados intuitiva e indicada para comparação de métodos, foi incluída uma tabela semelhante (Tabela 1) aplicada a alguns dos artigos de investigação que serviram de referência para este estudo. Para esta representação, foram incluídos trabalhos de investigação científica que utilizam modelos de ML de tipologias muito variadas.

Tabela 1 - Métodos de ML utilizados em problemas de análise e classificação de comportamentos de condutores rodoviários.

Referência	Instrumentos de recolha	Técnicas de análise	Objeto de investigação	Considerações
Mantouka and Vlahogianni, 2022	Microsimulação	<i>Deep Reinforcement Learning</i>	Recomendações de condução personalizadas	Embora as recomendações diminuam o risco, não se verifica melhoria das condições de tráfego

Referência	Instrumentos de recolha	Técnicas de análise	Objeto de investigação	Considerações
Al-Rakhami <i>et al.</i> , 2021	<i>Dataset</i> obtido com dados de sensores; simulação	<i>Deep Neural Network</i> (DNN)	Análise de comportamentos dos condutores	Computação na nuvem para treino de um modelo com base numa grande quantidade de dados
Lattanzi and Freschi, 2021	Dataset público, com dados de sensores de viaturas (unidades de controlo eletrónicas – <i>ECUs</i>)	<i>Support Vector Machines</i> e <i>Feed-Forward Neural Networks</i>	Classificação de perfis de condutores	Autores propuseram método para classificar comportamentos através de janelas temporais de condução
Li <i>et al.</i> , 2021	Dados de dinâmicas de veículos (velocidade, aceleração, ângulos de viragem, posição dos pedais)	<i>Unsupervised Bayesian algorithms</i>	Análise de comportamentos dos condutores para condução autónoma	O modelo proposto permite analisar relação entre manobras de condução e sinais comportamentais, de forma automática.
Shahverdy <i>et al.</i> , 2020	Sensores (acelerómetro, gravidade, RPM, velocidade e potência)	<i>Convolutional neural networks</i> (CNN)	Análise de comportamentos dos condutores	Necessidade de converter sinais em imagem para CNN
Naurois <i>et al.</i> , 2019	Análise e classificação de vídeos de condução em simulação, com ambiente controlado.	<i>Artificial Neural Network</i> (ANN)	Análise de estados de sonolência do condutor	Dos dois modelos testados, o com melhores resultados utiliza indicadores comportamentais e o perfil de condução
Matousek <i>et al.</i> , 2019	Sistema de simulador de tráfego “Simulation of Urban Mobility” (SUMO)	<i>Long Short-Term Memory</i> (LSTM); <i>Replicator Neural Network</i>	Detetar comportamentos de condução anómalos	Comparação da performance de uma rede do tipo <i>Replicator Neural Network</i> com uma rede do tipo LSTM
Zhu <i>et al.</i> , 2018	Sistema de simulador de condução	<i>Bionic Intelligent algorithms</i>	Análise de comportamentos dos condutores	Necessidade de sistema de simulação

Referência	Instrumentos de recolha	Técnicas de análise	Objeto de investigação	Considerações
Singh <i>et al.</i> , 2017	Sensores (acelerómetro, giroscópio, gravidade e GPS)	<i>Dynamic Time Warping</i> (DTW)	Análise de comportamentos dos condutores	Modelo simplificado; Indicado para dispositivos de pequena escala (<i>smartphones</i>)
* Valente <i>et al.</i> , 2023	APIs, Sensores de telemóvel (acelerómetro, giroscópio, gravidade e GPS)	<i>Agglomerative Hierarchical Algorithm</i> , <i>Random Forest</i> , <i>SVM</i>	Análise de comportamentos dos condutores	A técnica que revelou melhores resultados foi o K-Means

* Estudo anterior que utilizou técnicas de ML tradicionais.

2.3 Modelo de redes LSTM

Após a revisão bibliográfica efetuada, constata-se que os modelos de Redes Neurais Recorrentes (RNR) do tipo LSTM demonstram bons resultados de desempenho para estudos com características semelhantes às do que se pretende desenvolver (Chen *et al.*, 2024; Ma *et al.*, 2023; Xu *et al.*, 2022; Gui *et al.*, 2021; Saleh *et al.*, 2017; Morton *et al.*, 2016). A principal vantagem na utilização de redes neurais recorrentes, é que possuem ciclos no seu processo que permitem que alguma da informação persista ao longo da rede (Bansal *et al.*, 2022; Olah, 2015). De facto, a falta desta capacidade de persistência de informação tende a ser um problema que afeta as redes neurais de outras tipologias. A capacidade em reter informação faz com que as redes LSTM sejam extremamente capazes em lidar com informação em forma de sequência ou de lista relacionada (Zaini *et al.*, 2023).

O fator característico das redes LSTM, dentro das redes recorrentes, é que as camadas escondidas (*hidden layers*) são células do tipo LSTM (Morton *et al.*, 2016). Embora as RNR também sejam capazes de reter informação, na prática a sua performance tende a ser insuficiente quando se pretende lidar com informação persistente de longa duração (Olah, 2015). Tal como o nome indica, as LSTM são direcionadas precisamente para essas situações, para dados que envolvam dependências de longo termo (Zaini *et al.*, 2023). Cada bloco de uma rede LSTM é composto por 3 unidades de barreira:

- Barreira de esquecimento (“*forget gate*”): A sua função é fazer o controlo da informação de saída do bloco anterior. Representada por f_t , na função (1).

- Barreira de entrada (“*input gate*”): É responsável por adicionar a nova informação de entrada à informação de saída anterior. Representada por i_t , na função (2).
- Barreira de saída (“*output gate*”): Faz o controlo da informação de saída do bloco da rede. Representada por o_t , na função (3).

A configuração de LSTM base contempla a aplicação da barreira de esquecimento, mas variações populares deste modelo envolvem a aplicação das 3 camadas em simultâneo, de forma a permitir que todas as camadas tenham acesso ao estado da célula (Olah, 2015). As três barreiras são normalmente expressas pelas seguintes funções:

$$(1) \quad f_t = \sigma(W_f X_t + W_f h_{t-1} + b_f)$$

$$(2) \quad i_t = \sigma(W_i X_t + W_i h_{t-1} + b_i)$$

$$(3) \quad o_t = \sigma(W_o X_t + W_o h_{t-1} + b_o)$$

Em que σ representa a função sigmoide, W representa as matrizes de peso, h_t refere-se à *hidden layer* de saída e b representa o vetor de enviesamento (“*bias vector*”). Importa ressaltar que nem todas as aplicações de LSTM usam as camadas o_t e i_t . No contexto apresentado, h_t pode ser calculado através da função (4):

$$(4) \quad h_t = o_t \cdot \text{relu}(c_f)$$

Em que *relu* se refere à função de ativação. Por fim, o estado da célula c_t pode ser calculado utilizando a função:

$$(5) \quad c_t = \sigma(W_c X_t + W_c h_{t-1} + b_c)$$

As funções representadas por f_t , i_t , o_t e c_t podem assumir valores entre 0 e 1, em que 0 sinaliza que o valor em causa é descartado enquanto 1 sinaliza que o valor é para ser mantido (Zaini *et al.*, 2023; Olah, 2015). Por sua vez, h_t pode variar entre -1 e 1. Utilizando uma representação visual, na figura 3 encontra-se representada a estrutura de um segmento de rede LSTM, com os seus principais componentes identificados. Nesta figura, a função de ativação é representada por *tanh*, e não por *relu*.




Figura 3 – Esquema de funcionamento de uma rede do tipo *Long-Short Term Memory* (LSTM). Adaptado de Olah (2015).

Existem outras variações de LSTM possíveis, assim como outros modelos de RNN que utilizam metodologias diferentes para lidar com problemas de dependências a longo termo (Olah, 2015). As principais vantagens que são associadas a estas redes são a grande precisão obtida em modelos de previsão e a persistência da sua memória durante longos intervalos de tempo. Algumas desvantagens podem também ser identificadas, como o seu elevado consumo de tempo e de memória de processamento, o que impõe uma barreira em termos de hardware necessário e alguns problemas no ajuste do modelo que podem ser difíceis de resolver (Bansal *et al.*, 2022). Outra consideração importante é que, na altura de treino das redes neurais, o afinamento de alguns hiper-parâmetros como a rapidez de aprendizagem e a taxa de regularização podem ser fundamentais para obter modelos de elevada qualidade (Morton *et al.*, 2016).

Considerando o anteriormente referido, e tendo em conta o grau de precisão elevado que tende a ser associado a estes modelos, em tarefas de previsão (Bansal *et al.*, 2022), foi decidido utilizá-lo como foco deste estudo, e avaliar a sua utilização para o conjunto de dados de que se dispõe.

3. Materiais e Métodos

Neste capítulo será feita uma descrição pormenorizada dos métodos e pressupostos tomados durante as diferentes fases do projeto. Esta informação deverá servir para análise e validação das práticas adotadas e para contextualização dos resultados obtidos. Uma vez que o sistema desenvolvido inclui componentes com funcionalidade diferentes, e que utilizam linguagens e métodos de desenvolvimento específicos, foi opção separar este capítulo em subcapítulos direcionados a cada módulo do sistema.

A realização desta tese vem na sequência de um projeto iniciado anteriormente. Durante o ano letivo anterior, 2021-2022, foi desenvolvido um projeto de grupo pelo autor e outros colegas (Valente *et al.*, 2023). Este projeto foi enquadrado no mesmo tema e pretendia servir como prova de conceito, de forma a planear a estrutura de dados a utilizar, técnicas de recolha e processamento de dados, e a viabilidade geral da estrutura então definida. Tendo em conta a elevada importância de alguns dos módulos anteriormente desenvolvidos, e para permitir maior clareza do funcionamento de todo o processo, alguma informação anterior teve de ser novamente repetida neste relatório. Não obstante, devido às alterações metodológicas que ocorreram entre a finalização do projeto anterior e o início deste, muitos dos componentes existentes tiveram de sofrer ajustes ou melhorias funcionais. Nestas situações, o trabalho que foi desenvolvido anteriormente encontra-se demarcado de forma explícita, e com o contexto necessário para a sua total compreensão.

3.1 Planeamento do projeto

Na sequência do nosso projeto, foi definida a estrutura de dados, as metodologias de recolha de dados, e foi concretizada uma versão de protótipo da aplicação de recolha de dados, utilizando vários sensores de telemóvel e API's públicas para definir dados adicionais de informação de estradas e estado do tempo.

No projeto inicial foi feita um processamento de dados inicial, utilizando diferentes modelos de *Machine Learning* aprendidos durante o mestrado. Em concreto, foram aplicadas algumas técnicas de pré-processamento como a Análise de Componentes Principais (PCA), redução de características e estandardização de dados, para melhorar o processo de análise. Posteriormente, foram aplicados os modelos “*K-Means*”, “*Algorithm Agglomerative Hierarchical*”, “*Random Forest*” e “*Support Vector Machines*” para detetar padrões nos dados e fazer uma análise de sucesso e viabilidade dos modelos utilizados. No final, foi proposta uma potencial interface visual (*dashboard*) baseada na biblioteca de PHP “*Laravel*”, e em Javascript, para facilitar a compreensão dos dados por parte do utilizador.

Esta prova de conceito teve o nível de sucesso necessário para que fosse decidido progredir com este estudo. Desta forma, foi decidido completar a aplicação móvel para alargar a lista de potenciais utilizadores, alterar a recolha de dados para que fosse possível ao utilizador classificar diretamente o seu estilo de condução, e analisar a aplicação de modelos de inteligência artificial mais complexos, recorrendo a redes neuronais.

A estrutura de dados adotada para este estudo foi então praticamente a mesma que já tinha sido desenhada anteriormente, com a única diferença que foi adicionada uma característica de classe aos objetos de dados recolhidos durante as viagens. Na imagem 3 pode ser observada a estrutura de dados completa para este projeto.




Figura 4 - Estrutura global de dados e relações entre as diversas tabelas.

3.2 Aplicação Android

Como referido, foi desenvolvida uma aplicação para Android, utilizando a linguagem Kotlin, para fazer a leitura e registo dos dados de condução. A principal vantagem em utilizar Kotlin é que esta linguagem de programação é multiplataforma, podendo ser compilada para web, android e iOS, sendo mesmo recomendada pela Google para o desenvolvimento de aplicações para Android. A aplicação possui várias funcionalidades essenciais:

1. Possui um conjunto de páginas com formulário que para registar novos utilizadores, introduzindo informação pessoal e dados da viatura;
2. Inclui duas páginas, com a “Política de Privacidade” e os “Termos de serviço”, para colocar a informação legal pertinente;
3. Tem uma página de início de sessão, para iniciar uma nova série de registos para um utilizador já registado;
4. Possui um componente de mapa que utiliza a API do *Google Maps* para validação e para fornecer um indicativo visual para o local onde o utilizador se encontra;
5. Em conjunto com a componente de mapa, existe um módulo que faz o pedido dos dados dos sensores de telemóvel, e faz a gestão e comunicação dos dados com as API's.

Como já referido anteriormente, são utilizadas 2 API's externas para requerer dados da condição das estradas e o estado do tempo, nas coordenadas onde o utilizador se encontra. Estes dados são depois registados e enviados, juntamente com os dados dos sensores, para uma API em PHP, que faz a comunicação com a base de dados. O processo de registo de utilizador é também feito desta forma, utilizando outra funcionalidade da API para fazer a gestão dos registos.

Anteriormente a esta tese, durante o projeto desenvolvido no ano anterior, o funcionamento geral do módulo de mapa, de início de sessão, e parte do registo de utilizador já se encontravam feitos. No entanto, durante a duração deste projeto, foi necessário concluir o módulo de registo de utilizador e fazer algumas mudanças estruturais à componente de mapa e de registo de dados, para adaptar aos requisitos atuais. Nomeadamente, o mecanismo de registo através da app de viaturas e de algumas informações pessoais foram acabados; o mapa foi revisto para adicionar um ícone com a sinalização do utilizador e corrigir alguns bugs de registo periódico de dados; e foi adicionada uma caixa de seleção, abaixo do mapa, para escolher a classe de condução atual, para classificação manual de dados para usar no treino das redes neuronais. Adicionalmente, foram corrigidos alguns bugs encontrados que afetavam a experiência de utilização.

Na figura 5 é possível ver algumas figuras representativas de alguns dos diferentes elementos da aplicação desenvolvida.




Figura 5 – Imagens de alguns dos diferentes ecrãs da aplicação de android.

À direita encontra-se o ecrã de login, ao centro um dos ecrãs de registo de utilizador, e à direita o ecrã de viagem e registo de dados.

3.3 Recolha de dados

A recolha de dados foi feita a partir do momento em que o registo de utilizadores pela aplicação e o registo de dados passaram a estar completamente funcionais. A aplicação foi distribuída com alguns dos professores que orientavam a unidade curricular, de forma a testar e recolher dados com perfis diferentes. Num momento inicial foi feito o registo do utilizador, de forma a permitir o acesso à restante aplicação. Embora a recolha inicial tenha começado no início de 2023, foi detetado um bug na aplicação que acontecia no momento da recolha de dados dos sensores e das coordenadas de GPS. Infelizmente, este bug fazia com que, em determinadas condições, o registo de dados poderia ficar bloqueado a uma posição geográfica durante algum tempo. Assim, alguns grupos de registos foram efetuados com uma única coordenada geográfica. Quando este erro foi detetado, foi corrigido o bug na aplicação e foi disponibilizada uma nova versão da mesma. Ainda assim, o fato de os dados referentes a este período terem as coordenadas

erradas em alguns momentos de recolha, inviabilizaram a utilização dos mesmos, uma vez que a localização de GPS era uma característica fundamental para os pedidos de dados às API's, no que toca às condições da estrada e condições climáticas. Assim, de forma a garantir a integridade dos resultados, foi decidido descartar os dados de recolha que foram obtidos antes do bug na recolha da localização ser corrigido. Nos resultados finais só passaram a constar dados que foram recolhidos no período entre Abril a Junho de 2023.

Devido às limitações de tempo, e de forma a permitir a recolha da maior quantidade de dados possível, o momento de recolha de dados foi feito ao critério de cada utilizador, antes de iniciar uma nova viagem. O utilizador introduzia os dados de início de sessão, ficando a aplicação em espera, na vista de mapa, onde se pode fazer a seleção da classe de condução que se irá efetuar. Depois disto, o utilizador poderia decidir iniciar o registo de dados em qualquer altura, através do botão disponível. O design da aplicação permitia alterar a classe de dados numa mesma viagem, se o utilizador achasse que as condições de condução se iriam alterar.

Observaram-se outras limitações práticas durante esta fase do projeto. Um fator importante, é que, de forma a alargar a fase de recolha de dados a vários condutores, com necessidades específicas diferentes, não foi formulado um protocolo rígido no que diz respeito às condições de condução. A única condição proposta foi a de manter o estilo de condução adequado à classe que foi escolhida pelo utilizador. Isto implicou que alguns dos percursos efetuados tenham sido percorridos em múltiplas viagens, enquanto outros percursos tenham sido percorridos apenas uma vez. Adicionalmente, como o período de recolha de dados ocorreu num intervalo de tempo limitado, as condições climáticas encontradas durante a recolha de dados não foram muito diversas. De facto, durante o período de recolha de dados, o clima registado apenas sofreu alterações ligeiras, variando entre sol a períodos de nuvens, mas nunca com chuva. As temperaturas que se manifestaram também se mantiveram relativamente constantes, sem variações muito significativas nas condições de condução.

Estes fatores levaram a que as condições de recolha de dados não tenham sido as desejadas, em termos de rigor científico. As limitações de tempo e de recursos humanos impostas, para um projeto de relativa curta duração, levaram a algumas limitações que tiveram de ser ultrapassadas. Assim, os resultados deste estudo deverão ser vistos como uma investigação preliminar, onde foram testados os conceitos propostos para realizar a recolha e processamento de dados de condução.

3.4 Processamento de dados

Após a recolha de dados de condução, estes foram compilados num ficheiro csv, de forma a manter a integridade dos resultados e manter coerente o processo de análise e construção dos modelos. O processamento de dados foi realizado utilizando a aplicação *Jupyter Notebook*, que utiliza a linguagem de programação *python*, para fazer os algoritmos necessários ao processamento e análise de dados. Para a fase de processamento dos dados foram tidas em consideração as características dos dados que foram recolhidos. Todas as operações descritas de seguida visaram o *dataset* final, construído em *python* utilizando as bibliotecas *Pandas* e *Numpy*, duas bibliotecas popularmente utilizadas para este tipo de tarefas.

Numa fase inicial foi analisada a estrutura de dados existente e a pertinência das várias características que foram recolhidas. Devido às limitações de recursos humanos e de meios existentes, foi decido retirar a maioria dos dados de identificação do condutor e da viatura, uma vez que a variabilidade destes dados foi muito reduzida, o que injustificava a sua utilização. Um outro motivo para manter a anonimidade dos dados enquadrava com a proteção de dados, e os regimes legais de proteção que se encontram em vigor. Assim, a estrutura de dados final que foi utilizada para o treino dos modelos de ML incluiu 17 características distintas, que se podem observar na tabela 2. A escolha destas características pareceu-me adequada por incluir dados de diversos fatores que poderiam ter impacto no processo de condução.

Tabela 2- Características do conjunto de dados utilizado para análise e construção dos modelos de ML.

	Características	Quantidade dados	Tipo de dados
1	Tipo estrada	6253	Numérico
2	Velocidade atual	6253	Numérico
3	Velocidade de fluxo livre	6253	Numérico
4	Temperatura	6253	Numérico
5	Pressão atmosférica	6253	Numérico
6	Visibilidade	6253	Numérico
7	Velocidade vento	6253	Numérico
8	Densidade nuvens	6253	Numérico
9	Acelerómetro (vetor X)	6303	Numérico
10	Acelerómetro (vetor Y)	6303	Numérico
11	Acelerómetro (vetor Z)	6303	Numérico
12	Giroscópio (vetor X)	6303	Numérico
13	Giroscópio (vetor Y)	6303	Numérico
14	Giroscópio (vetor Z)	6303	Numérico

	Características	Quantidade dados	Tipo de dados
15	Altitude	6303	Numérico
16	Latitude	6303	Numérico
17	Longitude	6303	Numérico
18	Classe de condução	6303	Categórico

Com a estrutura de dados referida na tabela 2, procedeu-se a um tratamento de dados inicial. Como se pode observar na tabela, a quantidade de dados obtidos não foi igual para todas as características utilizadas. Isto aconteceu porque, durante o processo de recolha de dados, existiram instâncias em que os pedidos de informação pelas APIs de clima e de condição de estradas não se coordenaram corretamente com a recolha de dados dos sensores. Assim, verificou-se uma pequena diferença no número de dados recolhidos pelos sensores e pelas APIs. Em analítica, este tipo de situações é conhecido como “*Missing values*”, ou valores perdidos.

Nestas situações, existem algumas opções que se podem tomar, as quais dependem da quantidade de valores perdidos, assim como da quantidade de objetos de dados do *dataset*. Quando a quantidade de valores perdidos é pequena, podem-se utilizar técnicas como a utilização do valor da média, ou mediada, para substituir o valor perdido. No entanto, a utilização desta técnica em muitas características e objetos de dados pode implicar a diminuição da variância dos dados. Existem outros métodos de substituição de dados, como técnicas de interpolação ou duplicação dos valores adjacentes, mas que tendem a ter implicações semelhantes na diminuição da variância dos dados, ou a introduzir enviesamentos. Outra solução passa por remover os objetos de dados que possuem valores perdidos. Embora mais drástica, esta solução pode ser aplicada se o número de dados em falta não for muito elevado, face ao número de objetos de dados do *dataset*.

Considerando que os dados perdidos ocorreram em várias características e em múltiplos objetos de dados, optou-se por não realizar métodos de substituição dos valores desconhecidos. Assim, e para manter uma estrutura coesa em todo o *dataset*, foi feita uma limpeza dos 50 objetos de dados que possuíam valores nulos para a informação das APIs. Desta forma foram registados 6253 objetos de dados no *dataset* final, referentes aos vários registos de condução para todas as classes em análise.

Um segundo problema encontrado diz respeito ao desfasamento de dados que foram recolhidos para cada classe. Devido à sua natureza, os dados de comportamentos de risco foram recolhidos em menor quantidade, e apenas quando garantidas as condições de segurança. Isto originou uma sub-representação de algumas classes de comportamentos. Para reduzir este efeito, optou-se por reduzir o número de classes existentes, e condensar os diferentes comportamentos de risco numa única classe. Esta

opção, embora limitando a quantidade de informação que se poderá prever pelo modelo de LSTM, continua a permitir endereçar o objetivo principal do projeto. Assim, o modelo de LSTM obtido permitirá apenas fazer a deteção de comportamentos normais ou comportamentos de risco.

Embora um dos objetivos estabelecidos inicialmente consistia em treinar um modelo que permitisse detetar o tipo de comportamento de risco do condutor, tal não foi possível concluir neste estudo. Foram feitos testes utilizando alguns dos modelos descritos, mas a quantidade de dados de cada classe de comportamentos não se revelou suficiente para fazer classificações detalhadas com sucesso. Um conjunto de dados mais variado, com maior número de condutores e de variedade de condições, seria então necessário para fazer um estudo com maior nível de detalhe. Ainda assim, a classificação do tipo de comportamento seria uma necessidade de menor prioridade, uma vez que a principal preocupação será sempre a deteção de um comportamento considerado como sendo de risco. Assim, não sendo possível concretizar o objetivo secundário, nas secções restantes será dado ênfase ao modelo principal, de deteção de comportamentos de risco.

Depois de resolvidas as questões relativas à qualidade dos dados, foi feita a separação do *dataset* em dois subconjuntos de dados, um para treino do modelo, e outro para testes de precisão. A separação foi feita atribuindo 75% dos dados recolhidos para o conjunto de treino, o que consistiu em 4689 objetos de dados para o conjunto de treino, e 1564 objetos de dados para o conjunto de teste. Finalmente, utilizando a biblioteca *sklearn*, foi feita uma standardização dos dados, de forma a normalizar as diferenças de escala existentes nas diferentes características do *dataset*, permitindo assim a sua comparabilidade. Foram também feitas algumas alterações na estrutura com que os dados estavam registados, para utilizar a estrutura convencional do *numpy* que seria necessária para utilizar os dados para o treino dos modelos de ML. Esta alteração apenas foi feita por necessidade das bibliotecas de modelação de ML.

3.5 Modelo de LSTM

Em Valente *et al.*, (2023) foi testada uma metodologia semelhante, mas que visava a aplicação de técnicas de ML tradicionais, para compreender padrões de condução. Algumas das técnicas testadas envolveram a aplicação de modelos como o Algoritmo Aglomerativo Hierárquico, Máquinas de Suporte de Vetores, *K-means* e *Random Forest*. Nesta fase do projeto, os modelos foram treinados com um conjunto de 555 objetos de dados, e 26 características, não estando ainda implementada a classificação dos dados.

Para este estudo, e como referido no enquadramento teórico, o modelo de rede neurais adotado são as LSTM's. Este tipo de redes neurais recorrentes foi alvo de alguns estudos de investigação no domínio da condução (Chen *et al.*, 2024; Ma *et al.*,

2023; Xu *et al.*, 2022; Gui *et al.*, 2021; Matousek *et al.*, 2019; Saleh *et al.*, 2017; Morton *et al.*, 2016), uma vez que possuem boas capacidades em aprender características de natureza temporal e espacial.

O modelo testado envolveu a utilização da biblioteca *Keras*, tendo sido aplicado um modelo sequencial com 4 camadas - *hidden layers* - do tipo LSTM. No treino inicial, foi testada uma configuração que utilizava o otimizador “Adam”, a função de perdas “erro quadrático médio”, 100 *epochs* e um tamanho de *batch* de 64.

De forma a testar várias configurações e combinações de hiper-parâmetros, foi desenvolvida uma função própria capaz de treinar modelos sequencialmente, com várias combinações do número de *epochs*, diferentes tipos de otimizador e de tamanhos de *batch*. Esta função foi depois utilizada para testar um total de 12 cenários diferentes, com configurações ligeiramente diferentes, de forma a tentar encontrar qual seria a mais adequada. Importa referir que, de forma a encontrar os hiper-parâmetros com maior importância, as combinações envolveram alterações a apenas 1 parâmetro de cada vez. No final do teste de configurações, foram compilados os dados respetivos a cada variação.

Finalmente, foram também utilizadas as bibliotecas de *matplotlib*, especificamente o módulo de *pyplot* que permite fazer a visualização de dados em formato gráfico. Esta biblioteca foi sobretudo utilizada para desenhar os gráficos que indicam a evolução das métricas de treino do modelo inicial, representados na figura 7. Para os restantes elementos gráficos que se encontram no documento, foi utilizado complementarmente o programa *Excel*, distribuído pela Microsoft, onde foram introduzidos os dados obtidos durante o processo de análise do modelo. A escolha deste método deveu-se à maior familiaridade com este programa, assim como pela grande capacidade de personalização que este permite.

4. Resultados

Da análise geral ao modelo obtido, a utilização de 4 camadas de LSTM envolveu o treino de 71.051 parâmetros, sem qualquer falha registada. O valor de precisão das previsões que foram obtidas para este modelo (matriz de confusão) foi de 93,47%. Com a função de perda utilizada (erro médio quadrado), obteve-se na fase final do treino um valor de perda estava situado em 0.044. A evolução dos valores de perda e de precisão, obtidos durante o treino do modelo inicial, podem ser observadas na figura 7




Figura 6 – Evolução das métricas de treino do modelo inicial.

Utilizando o método *Predict* que está associado ao modelo Sequencial da biblioteca Keras, podemos fazer previsões de um conjunto de dados de teste e comparar com as classes originais. Quando realizado este teste, foi prevista a ocorrência de 491 comportamentos de risco e de 1073 comportamentos seguros, enquanto os resultados reais mostraram a ocorrência de 424 comportamentos de risco e de 1140 comportamentos seguros. Na figura 7 pode ser observado o resultado deste teste, realizado através da aplicação Jupyter Notebook.

```
In [81]: print("real normals: ", np.count_nonzero(y_test == 0))
print("real risky: ", np.count_nonzero(y_test == 1))
print("predicted normal: ", np.count_nonzero(predicted_values == 0))
print("predicted risky: ", np.count_nonzero(predicted_values == 1))

real normals: 424
real risky: 1140
predicted normal: 491
predicted risky: 1073
```

Figura 7 – Resultado dos testes de previsão de comportamentos.

De seguida iremos analisar o impacto das variações aos hiper-parâmetros, segundo os processos descritos anteriormente, e que se encontram representados na tabela 3. É possível observar que apenas ocorreram pequenas variações na precisão, para todas as configurações testadas. Enquanto apenas uma das configurações apresentou o valor de performance mais baixo (92.054% - otimizador Adamax; 250 *epochs*; tamanho de *batch*: 32), existiu um empate entre 3 modelos para os melhores resultados obtidos. Na tabela 3 podem ser observados os resultados obtidos para as diferentes configurações de hiper-parâmetros.

Tabela 3 – Tabela com resumo dos resultados obtidos, durante as iterações aos parâmetros do modelo de LSTM. As combinações de hiper-parâmetros com melhores valor de precisão encontram-se destacadas.

Optimizador	Tamanho do <i>batch</i>	<i>Epochs</i>	Precisão	Positivos Corretos	Positivos Incorretos	Negativos Incorretos	Negativos Corretos
Adam	32	50	93.542%	388	36	65	1075
Adam	32	100	94.054%	394	30	63	1075
Adam	32	250	92.839%	385	39	73	1067
Adamax	32	50	93.542%	387	37	64	1076
Adamax	32	100	93.990%	390	34	60	1080
Adamax	32	250	93.862%	393	31	65	1075
Adam	64	50	93.095%	391	33	75	1065
Adam	64	100	94.118%	392	32	60	1080

Optimizador	Tamanho do <i>batch</i>	<i>Epochs</i>	Precisão	Positivos Corretos	Positivos Incorretos	Negativos Incorretos	Negativos Corretos
Adam	64	250	94.118%	384	40	52	1088
Adamax	64	50	94.118%	393	31	61	1079
Adamax	64	100	93.990%	392	32	62	1078
Adamax	64	250	93.926%	392	32	63	1077

Importa destacar que, mesmo tendo em conta os diferentes hiper-parâmetros testados, a configuração das camadas do modelo foi igual para todos: 4 *hidden layers* do tipo LSTM e uma camada de saída. Devido a isto, as variações verificadas são de natureza muito baixa, com a diferença máxima detetada a ser inferior a 2%, entre as melhores e a pior configuração. Assim, do ponto de vista estatístico, as diferenças encontradas não possuem grande significância, tendo todas as configurações atingido bons valores de precisão. Para mais fácil leitura dos resultados, na figura 6 encontra-se um gráfico de barras com a comparação dos resultados de precisão obtidos.




Figura 8 – Gráfico de comparação das percentagens de precisão obtidas para diferentes comparações de parâmetros.

Embora as colunas do gráfico estejam representadas numa escala um pouco exagerada, o gráfico obtido permite-nos observar de forma mais clara as diferenças de precisão que ocorreram entre as diferentes configurações testadas. Assim, podemos confirmar que as variações que ocorreram tiveram impacto reduzido na performance dos modelos, havendo uma ligeira tendência para melhores valores de precisão obtidos quando utilizados *batches* de maior dimensão. As variações que ocorreram para os diferentes optimizadores utilizados e para os tamanhos de *epochs* não nos permitem

observar nenhuma tendência, podendo estes ter pouco impacto sobre a qualidade do modelo, para a configuração testada.

Por fim, podemos observar em maior detalhe a forma como as previsões se distribuíram pelas diferentes configurações. Na figura 7 estão representadas, com fundo branco, as matrizes de confusão das 3 configurações que obtiveram melhor precisão, assim como da configuração que obteve pior precisão, com fundo azul.




Figura 9 – Gráficos de comparação das matrizes de confusão para diferentes comparações de parâmetros. Os gráficos com fundo branco representam os parâmetros que obtiveram melhor precisão. O gráfico a azul representa o conjunto de parâmetros que obteve pior precisão.

Da análise a estes resultados, podemos determinar que, em todas as configurações, o principal fator de erro foi a classificação incorreta de comportamentos seguros (negativos incorretos). Ou seja, os modelos obtidos apresentaram maior percentagem de erro ao classificar alguns comportamentos como seguros, mas que na realidade eram de risco. Embora este comportamento tenha acontecido em todas as configurações testadas, na configuração que utilizou o otimizador Adam, 250 *epochs* e um *batch* com tamanho de 64 unidades os valores de erro foram mais próximos um do outro, o que poderá indicar uma ligeira melhoria na capacidade de identificar padrões distintivos. Ainda assim, tendo em conta os valores de precisão obtidos, acima de 91%, não podemos não estar comprometida a capacidade preditiva de cada uma das configurações testadas, mesmo na configuração com precisão mais reduzida.

5. Discussão

Quando comparamos os dados que foram obtidos com os dados de outros estudos semelhantes, podemos observar semelhanças com a maioria dos resultados encontrados, em que a utilização deste tipo de modelos permitiu obter valores graus de precisão bastante satisfatórios. No estudo de Ma *et al.*, (2023), os autores concluíram que o modelo de LSTM utilizado obteve melhores resultados que os restantes modelos aplicados. Adicionalmente, os autores notaram também que o modelo de LSTM não foi particularmente sensível a variações nos seus parâmetros, o que também foi constatado neste estudo. As implicações observadas pelos autores deste estudo podem ter implicações importantes para trabalhos futuros, especialmente no que respeita às modificações implementadas para permitir deteção de comportamentos em tempo real. Infelizmente o artigo em causa foi publicado durante a execução deste projeto, pelo que as suas contribuições só foram reconhecidas de forma posterior.

Na investigação desenvolvida por Xu *et al.* (2022), os autores concluíram igualmente a utilização de um modelo de LSTM permitiu obter melhores resultados que os obtidos por outros modelos de ML. Igualmente interessante, os autores deste estudo aplicaram mecanismos complementares (um mecanismo de atenção e o modelo *Hidden Markov*) para melhorar a performance do modelo LSTM, o que conseguiram igualmente comprovar (Xu *et al.*, 2022).

Uma das limitações encontradas durante este estudo foi a quantidade de recursos necessários, tanto em tempo disponível como em recursos humanos, para obter um conjunto de dados mais extenso, como seria desejado. Tipicamente, os modelos de *Deep Learning* necessitam de quantidades de dados extensas para obter modelos com a melhor qualidade possível. Num estudo recente, Li *et al.*, (2021) referem que uma são necessárias aproximadamente 800 horas de trabalho para classificar os dados que dizem respeito a 1 hora de condução. A estratégia que foi por nós adotada, em pré-classificar os dados durante o ato da condução, ajudou a minimizar esta limitação, uma vez que eliminou a necessidade de classificar dados de forma manual. No entanto, esta implicou igualmente uma maior necessidade de tempo para o desenvolvimento da aplicação móvel, e da estrutura de dados onde foram efetuados os registos.

Num artigo de Raschka *et al.*, (2020), os autores sugerem que a ocorrência de desigualdades na distribuição das diferentes classes de um *dataset* pode ser um desafio considerável. As implicações deste tipo de fenómenos podem levar a que, durante a fase de treino do modelo de ML, este desenvolva enviesamento na sua capacidade de previsão. Especificamente, os autores referem que um desequilíbrio na ocorrência das várias classes pode fazer com que o modelo otimize a sua capacidade de previsão ao prever a classe que

ocorre na maioria dos objetos de dados (Raschka *et al.*, 2020). Estes tipos de considerações podem ser relevantes para os resultados encontrados neste estudo, uma vez que a quantidade de dados de condução normal foi mais frequente que os dados de condução de risco. Assim, para trabalhos que sejam conduzidos futuramente, poderia ser interessante tentar obter um conjunto de dados mais extenso e equilibrado, e comparar os resultados com os obtidos neste estudo.

Para trabalhos futuros, poderá ser dado um maior ênfase a obter um *dataset* com maior quantidade de dados e mais variados, sobretudo considerando que a estrutura de dados, a aplicação móvel, as *APIs* de suporte e os algoritmos de LSTM já se encontram desenvolvidos. Uma possível direção futura poderia ter como base a investigação desenvolvida por Xu *et al.* (2022), onde se poderia testar a aplicação de modelos complementares, que possam colmatar algumas das limitações dos modelos LSTM.

Outra possível direção de investigação poderia consistir em testar a aplicação deste tipo de modelos para diferenciar os comportamentos de risco dos condutores, ou testar outros modelos de DL que possam ser igualmente adequados. A estrutura de dados que foi desenhada, e que se encontra enquadrada na aplicação móvel, pode ainda permitir conduzir estudos futuros com outros objetivos diferenciados. A bibliografia que foi consultada, e referida nos capítulos iniciais, sugere um vasto conjunto de modelos possíveis, e que podem ter um alto interesse para aplicações distintas, focando-se em áreas de investigação mais específicas.

6. Conclusões

Neste relatório foi revista e proposta uma metodologia de recolha e tratamento de dados para classificação de perfis de condução. A principal contribuição deste projeto foi consolidar o método de recolha de dados anteriormente desenhado, obter uma nova série de dados de condução classificados, e propor um modelo de LSTM como forma de identificar a ocorrência de comportamentos de risco.

Tendo tudo em consideração, considero que foram atingidos os objetivos principais que foram propostos, tendo sido realizados melhoramentos e desenvolvimentos notórios nos sistemas envolvidos neste projeto. Com base na nova recolha de dados que foi realizada, foi ainda possível obter um modelo de LSTM que obteve dados relativamente encorajadores, com um valor máximo de precisão acima de 94%. Se compararmos os resultados com os obtidos anterior, segundo observado em Valente *et al.*, (2023), podemos observar que os resultados obtidos foram melhores que os registados nessa fase de desenvolvimento.

Embora algumas dificuldades encontradas tenham limitado a aplicação do modelo, os resultados obtidos servem como uma boa base para investigação futura, assim como permitiram validar alguns dos resultados encontrados na bibliografia consultada. Assim, a aplicação de modelos de redes neurais recorrentes, e em particular de modelos LSTM, demonstraram potencial elevado para conduzir estudos de classificação de perfis de condutores e previsão de comportamentos de risco.

Bibliografia

- Al-Rakhami, M.S., Gumaei, A., Hasan, M.M., Alamri, A., Alhussein, M., Razzaque, M.A., Fortino, G. (2021): A deep learning-based edge-fog-cloud framework for driving behavior management. *Computers and Electrical Engineering*, 96: 107573.
- Al-Sultan, S., Al-Bayatti, A.H., Zedan, H. (2013): Context-aware driver behavior detection system in intelligent transportation systems. *IEEE Transactions on Vehicular Technology*, 62 (9): 4264–4275.
- Bansal, M., Goyal, A., Choudhary, A. (2022): A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning. *Decision Analytics Journal*, 3: 100071.
- Chen, G., Gao, Z., Hua, M., Shuai, B., Gao, Z. (2024): Lane change trajectory prediction considering driving style uncertainty for autonomous vehicles. *Mechanical Systems and Signal Processing*, 206: 110854.
- Chong, L., Abbas, M.M., Flintsch, A.M., Higgs, B. (2013): A rule-based neural network approach to model driver naturalistic behavior in traffic. *Transportation Research Part C*, 32: 207–223.
- Du, Z., Deng, M., Lyu, N., Wang, Y. (2023): A review of road safety evaluation methods based on driving behavior. *Journal of Traffic and Transportation Engineering (English Edition)*, 10 (5): 743-761.
- Elassad, Z.E.A, Mousannif, H., Moatassime, H.A., Karkouch, A. (2020): The application of machine learning techniques for driving behavior analysis: A conceptual framework and a systematic literature review. *Engineering Applications of Artificial Intelligence*, 87: 103312.
- Eren, H., Makinist, S., Akin, E., Yilmaz, A. (2012): Estimating Driving Behavior by a Smartphone. *Intelligent Vehicles Symposium*. Alcalá de Henares, Spain, June 3-7.
- Fafoutellis, P., Mantouka, E.G., Vlahogianni, E.I., Fortsakis, P., (2023): Investigating the impacts of the COVID-19 pandemic on Eco-driving behavior. *Safety Science*, 166: 106251.
- Farag, G. (2019): Cloning Safe Driving Behavior for Self-Driving Cars using Convolutional Neural Networks. *Recent Patents on Computer Science*, 12: 1-8.
- Ghate, V. e Hemalatha, S. (2023): A comprehensive comparison of machine learning approaches with hyper-parameter tuning for smartphone sensor-based human activity recognition. *Measurement: Sensors*, 30: 100925.
- Galarza, E.E., Egas, F.D., Silva, F.M., Velasco, P.M., Galarza, E.D. (2018): Real time driver drowsiness detection based on drivers face image behavior using a system of

human computer interaction implemented in a smartphone. Em: International conference on information theoretic security (pp. 563–572). Springer.

- Gui, Z., Sun, Y., Yang, L., Peng, D., Li, F., Wu, H., Guo, C., Guo, W., Gong, J. (2021): LSI-LSTM: An attention-aware LSTM for real-time driving destination prediction by considering location semantics and location importance of trajectory points. *Neurocomputing*, 440: 72–88.
- Henrique, B.M., Sobreiro, V.A., Kimura, H. (2023): Practical machine learning: Forecasting daily financial markets directions. *Expert Systems With Applications*, 233: 120840.
- International Transport Forum (2022): Road Safety Annual Report 2022. OECD Publishing, Paris. (Consultado em Outubro de 2023, no site: <https://www.itf-oecd.org/sites/default/files/docs/irtad-road-safety-annual-report-2022.pdf>)
- Lattanzi, E. and Freschi V. (2021): Machine Learning Techniques to Identify Unsafe Driving Behavior by Means of In-Vehicle Sensor Data. *Expert Systems With Applications*, 176: 114818.
- Lyon, C., Vanlaar, W., Robertson, R.D. (2024): The impact of COVID-19 on transportation-related and risky driving behaviors in Canada. *Transportation Research Part F: Psychology and Behaviour*, 100: 13–21.
- Li, G., Chen, Y., Cao, D., Qu, X., Cheng, B., Li, K. (2021): Extraction of descriptive driving patterns from driving data using unsupervised algorithms. *Mechanical Systems and Signal Processing*, 156: 107589.
- Ma, Y., Xie, Z., Chen, S., Qiao, F., Li, Z. (2023): Real-time detection of abnormal driving behavior based on long short-term memory network and regression residuals. *Transportation Research Part C*, 146: 103983.
- Mantouka, E.G. and Vlahogianni, E.I. (2022): Deep Reinforcement Learning for Personalized Driving Recommendations to Mitigate Aggressiveness and Riskiness: Modeling and Impact Assessment. *Transportation Research Part C*, 142, 103770.
- Matousek, M., El-zohairy, M., Al-Momani, A., Kargl, F., Bösch, C., (2019): Detecting Anomalous Driving Behavior using Neural Networks. *IEEE Intelligent Vehicles Symposium (IV)*. Paris, France. June 9-12, 2019.
- Martinelli, F., Mercaldo, F., Orlando, A., Nardone, V., Santone, A., Sangaiah, A.K. (2020): Human behavior characterization for driving style recognition in vehicle system. *Computers and Electrical Engineering* 83: 102504.
- Morton, J., Wheeler, T.A., Kochenderfer, M.J. (2016): Analysis of Recurrent Neural Networks for Probabilistic Modeling of Driver Behavior. *IEEE Transactions on Intelligent Transportation Systems*, 18 (5) .

- de Naurois, C.J., Bourdin, C., Stratulat, A., Diaz, E., Vercher, J.-L. (2019): Detection and prediction of driver drowsiness using artificial neural network models. *Accident Analysis and Prevention* 126: 95–104.
- Olah, C (2015): Understanding LSTM Networks. Google Research. Disponível em: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Organização Mundial de Saúde (2011): Global launch: decade of action for road safety 2011-2020 (No. WHO/NMH/VIP11. 08). World Health Organization.
- Pratap, A. e Sardana, N. (2022): Machine learning-based image processing in materials science and engineering: A review. *Materials Today: Proceedings*, 62:7341–7347.
- Pordata (2023): Acidentes de viação em Portugal Continental: acidentes com vítimas, feridos e mortos. Consultado a Outubro 2023. Disponível em <http://www.pordata.pt>.
- Raschka, S., Patterson, J., Nolet, C. (2020): Machine Learning in Python: Main Developments and Technology Trends in Data Science, Machine Learning, and Artificial Intelligence. *Information*, 11: 193. Doi:10.3390/info11040193
- Sabokrou, M. , Pourreza, M. , Fayyaz, M. , Entezari, R. , Fathy, M. , Gall, J. , et al. (2018): Avid: adversarial visual irregularity detection. In *Asian conference on computer vision* (pp. 488–505). Springer . (Citado em Shahverdy *et al.*, 2020).
- Sagberg, F., Selpi, Bianchi Piccinini, G.F., Engström, J. (2015): A review of research on driving styles and road safety. *Human Factors* 57 (7): 1248–1275. <http://dx.doi.org/10.1177/0018720815591313>.
- Saleh, K., Hossny, M., and Nahavandi, S. (2017): Driving Behavior Classification Based on Sensor Data Fusion Using LSTM Recurrent Neural Networks. *IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*.
- Shahverdy, M., Fathy, M., Berangi, R., Sabokrou, M. (2020): Driver behavior detection and classification using deep convolutional neural networks. *Expert Systems With Applications*, 149: 113240.
- Singh, G., Bansal, D. and Sofat, S. (2017): A smartphone based technique to monitor driving behavior using DTW and crowdsensing. *Pervasive and Mobile Computing*, 40: 56–70.
- Singh, V., Chen, S.-S., Singhania, M., Nanavati, B., Kar, A.K., Gupta, A. (2022): How are reinforcement learning and deep learning algorithms used for big data based decision making in financial industries – A review and research agenda. *International Journal of Information Management Data Insights*, 2: 100094.
- Valente, J., Ramalho, C., Vinha, P., Mora, C., Jardim, S. (2023): Using machine learning to understand driving behavior patterns. *Procedia Computer Science* (Por publicar).
- Xiao, W., Liu, H., Ma, Z., Chen, W. (2022): Attention-based deep neural network for driver behavior recognition. *Future Generation Computer Systems*, 132: 152–161.

- Xu, W., Wang, J., Fu, T., Gong, H., Sobhani, A. (2022): Aggressive driving behavior prediction considering driver's intention based on multivariate-temporal feature data. *Accident Analysis and Prevention*, 164: 106477.
- Zaini, N., Ahmed, A.N., Ean, L.W., Chow, M.F., Malek, M.A. (2023): Forecasting of fine particulate matter based on LSTM and optimization algorithm. *Journal of Cleaner Production*, 427: 139233.
- Zhao, C., Gao, Z., Wang, Q., Xiao, K., Mo, Z., Deen, M.J. (2023): FedSup: A communication-efficient federated learning fatigue driving behaviors supervision approach. *Future Generation Computer Systems*, 138: 52–60.
- Zhu, B., Liu, Z., Zhao, J., Chen, Y., Deng, W. (2018): Driver behavior characteristics identification strategies based on bionic intelligent algorithms. *IEEE Transactions on Human-Machine Systems*, 99: 1–10.
- Zhu, M., Wang, J., Yang, X., Zhang, Y., Zhang, L., Ren, Y., Wu, B., Ye, L. (2022): A review of the application of machine learning in water quality evaluation. *Eco-Environment & Health*, 1: 107–116.
- Yu, J., Chen, Z., Zhu, Y., Chen, Y. J., Kong, L., Li, M. (2017): Fine-grained abnormal driving behaviors detection and identification with smartphones. *IEEE Transactions on Mobile Computing*, 16 (8): 2198–2212.

