

# Previsão de Acidentes Rodoviários em Portugal

José Cunha\*, José Silvestre Silva<sup>†</sup>, Ricardo Ribeiro<sup>‡</sup> and Paulo Gomes<sup>§</sup>

\*<sup>†§</sup>Centro de investigação da Academia Militar (CINAMIL), Academia Militar, 1169-203 Lisbon, Portugal

<sup>†</sup>LIBPhys-UC,LA-REAL, Universidade de Coimbra, 3030-709 Coimbra, Portugal

\*<sup>‡</sup>Instituto Superior Técnico, Universidade de Lisboa, 1049-001 Lisbon, Portugal

<sup>‡</sup>Instituto de Sistemas e Robótica, Universidade de Lisboa, 1049-001 Lisbon, Portugal

\* cunha.jll@gnr.pt, <sup>†</sup> jose.silva@academiamilitar.pt, <sup>‡</sup> ricardo.a.ribeiro@tecnico.ulisboa.pt, <sup>§</sup> gomes.pso@gnr.pt

**Abstract**—~~Road traffic accidents~~ (RTAs) remain a major global issue, contributing to a significant loss of life, injuries, and economic costs. Traditional safety measures, such as infrastructure improvements and law enforcement, are insufficient to mitigate the rising risk. This thesis explores the use of machine learning (ML) and deep learning (DL) models for predicting RTA severity, using a dataset from the Portuguese National Republican Guard (GNR). Models including Random Forest (RF), XGBoost, Multilayer Perceptron (MLP), and Deep Neural Networks (DNN) were evaluated based on environmental and traffic variables. Techniques to address imbalanced datasets, such as class weighting, SMOTE, and RUS, were applied. DNNs with class weighting achieved the highest recall for severe accidents (up to 60%) and a G-mean of 0.53, outperforming RF and XGBoost. Despite these improvements, all models struggled to predict severe accidents, while performing better on non-severe cases. This work highlights the potential of AI-driven predictive systems for traffic safety and resource allocation, while also noting limitations in real-world applicability.

**Keywords**—Road traffic accidents; accident severity prediction; machine learning; imbalanced datasets; GNR.

## I. INTRODUÇÃO

Os acidentes rodoviários continuam a ser uma grande preocupação de saúde pública, ceifando milhares de vidas todos os anos e exercendo uma forte pressão sobre os sistemas de emergência médica e as forças de segurança [1]. As medidas de segurança tradicionais, tais como melhorias nas infraestruturas e a fiscalização policial, têm-se mostrado insuficientes para prevenir acidentes em ambientes de tráfego cada vez mais complexos [2]. Resolver este problema exige métodos baseados em dados, capazes de antecipar situações de elevado risco antes que estas ocorram.

As técnicas de aprendizagem automática (machine learning - ML) e de aprendizagem profunda (deep learning - DL) surgiram recentemente como ferramentas poderosas para analisar dados de tráfego heterogêneos, identificar cenários propensos a acidentes e prever a gravidade dos mesmos [3], [4]. Embora os algoritmos tradicionais de ML, como as árvores de decisão e as máquinas de vetores de suporte, ofereçam um desempenho de classificação robusto, as arquiteturas modernas de DL, como as Multilayer Perceptrons (MLPs) e as redes neuronais profundas (DNNs), conseguem captar relações complexas e não lineares entre variáveis que incluem fatores meteorológicos, de iluminação e temporais [5]. Estas capacidades melhoram a previsão de desfechos raros mas críticos, tais como feridos graves e vítimas mortais.

Em Portugal, a Guarda Nacional Republicana (GNR) e a Polícia de Segurança Pública (PSP) desempenham papéis

fundamentais na fiscalização da segurança rodoviária. No entanto, o crescente volume de tráfego e a vasta área de jurisdição destas forças de segurança dificultam a atribuição eficiente de recursos e a antecipação de riscos em tempo real [6], [7]. A integração de modelos preditivos baseados em ML e DL poderá apoiar estas forças na monitorização de zonas de alto risco, na priorização de intervenções e na redução do impacto humano e económico dos acidentes de viação. Estes sistemas representam um passo em direção a uma abordagem mais proativa e baseada em dados na gestão da segurança rodoviária em Portugal.

## II. ESTADO DA ARTE

A investigação sobre a previsão de acidentes rodoviários tem adotado cada vez mais métodos de inteligência artificial, em particular a aprendizagem automática (machine learning - ML) e a aprendizagem profunda (deep learning - DL), de modo a melhorar a segurança rodoviária e a gestão de recursos. Estas técnicas permitem a análise de conjuntos de dados complexos e multidimensionais, que abrangem fatores ambientais, temporais e espaciais, oferecendo um desempenho superior em comparação com as abordagens estatísticas tradicionais [2], [8], [9].

### A. Métodos tradicionais de Aprendizagem Automática

Os algoritmos tradicionais de ML, tais como as árvores de decisão (Decision Trees), florestas aleatórias (Random Forests - RF), máquinas de vetores de suporte (Support Vector Machines - SVM) e métodos de Gradient Boosting (XGBoost, LightGBM), têm sido bastante aplicados na classificação da gravidade dos acidentes com base em dados históricos [2], [9], [10]. Os estudos destacam de forma consistente a eficácia das técnicas de ensemble (combinação de modelos) e de boosting na captura de relações não lineares entre as características associadas aos acidentes. Por exemplo, o XGBoost atingiu exatidões (accuracies) superiores a 85% em conjuntos de dados de grande escala no Reino Unido e na China [2], [11]. De igual modo, os modelos de RF otimizados por métodos Bayesianos melhoraram a precisão (precision) e a sensibilidade (recall) em conjuntos de dados regionais mais pequenos [8]. Apesar do seu sucesso, estes modelos dependem frequentemente de dados estáticos, carecem de validação inter-regional e revelam dificuldades na adaptação em tempo real e no desequilíbrio de classes, sendo estas as principais limitações para a sua implementação operacional.

## B. Técnicas de Aprendizagem Profunda

Os recentes avanços na aprendizagem profunda (DL) melhoraram ainda mais a previsão da gravidade dos acidentes, ao permitirem que os modelos aprendam dependências espaciais e temporais complexas. Arquiteturas como as redes neuronais convolucionais (Convolutional Neural Networks - CNNs), redes neuronais profundas (Deep Neural Networks - DNNs) e mecanismos baseados em atenção (attention-based mechanisms) demonstraram melhorias notáveis na exatidão. Jin e Noh [3] obtiveram um AUC-ROC de 93,2% utilizando um modelo híbrido CNN-DNN, enquanto Somvanshi et al. [12] introduziram o MambaAttention, que melhorou a sensibilidade (recall) para acidentes graves para 81% em conjuntos de dados fortemente desequilibrados. Da mesma forma, abordagens generativas como as redes adversariais generativas tabulares condicionais (Conditional Tabular Generative Adversarial Networks - CTGAN) têm sido aplicadas para aumentar as classes sub-representadas, resultando em pontuações F1 (F1-scores) próximas de 89% [13]. Estes modelos apresentam um forte desempenho preditivo, mas exigem elevados recursos computacionais e carecem frequentemente de interpretabilidade, o que dificulta a sua adoção prática em sistemas de tráfego do mundo real.

## C. Desequilíbrio de Dados e Generalização dos modelos

Um desafio persistente na literatura é o acentuado desequilíbrio de classes nos conjuntos de dados de acidentes, onde os acidentes mortais ou graves são raros quando comparados com os acidentes ligeiros [14]. Métodos de aprendizagem combinada para dados desequilibrados (ensemble imbalance learning), tais como Balanced RF, RUSBoost e OverBoost, têm sido propostos para melhorar a deteção da classe minoritária [15]. As técnicas de aumento de dados e os mecanismos de atenção atenuam ainda mais este problema, ao melhorarem a sensibilidade do modelo para os casos graves [12], [13]. No entanto, garantir a generalização entre diferentes regiões geográficas e condições de tráfego continua a ser um problema em aberto, uma vez que a maioria dos modelos é treinada em conjuntos de dados localizados, sem validação externa [16].

## D. Aplicação no Contexto de Portugal

Em Portugal, poucos estudos exploraram a utilização de ML e DL para a previsão de acidentes recorrendo a dados de forças de segurança, tais como a Guarda Nacional Republicana (GNR) [6], [10]. Os trabalhos existentes que utilizam dados da GNR aplicaram classificadores tradicionais de ML, como RF e Árvores de Decisão, atingindo exatidões próximas de 85%. Contudo, estas abordagens não incorporaram aprendizagem profunda nem estratégias para lidar com o desequilíbrio de classes, limitando a sua capacidade de detetar casos de acidentes graves. Esta lacuna realça a necessidade de integrar modelos modernos baseados em IA nos sistemas nacionais de segurança rodoviária, de modo a apoiar uma tomada de decisão proativa e fundamentada em dados.

## E. Summary

No geral, a literatura demonstra um progresso claro dos métodos tradicionais de ML para os de DL na previsão da gravidade dos acidentes. Contudo, persistem desafios significativos no que diz respeito ao desequilíbrio de dados, à adaptabilidade em tempo real, à interpretabilidade e à generalização regional. A resolução destas questões, em particular em contextos nacionais como o de Portugal, pode abrir caminho para sistemas de segurança rodoviária baseados em IA que sejam mais precisos, explicáveis e operacionalmente viáveis.

## III. DATASET E METODOLOGIA

Esta secção descreve o conjunto de dados, as etapas de pré-processamento, as arquiteturas dos modelos e as métricas de avaliação utilizadas neste estudo. Em primeiro lugar, apresenta-se uma visão geral da fonte de dados e das suas características, seguida dos métodos empregados para preparar os dados, abordar o desequilíbrio de classes e implementar os modelos preditivos. Por fim, são delineadas as métricas utilizadas para avaliar o desempenho dos modelos.

Aqui tem a tradução da subsecção relativa aos dados, com especial atenção às nomenclaturas institucionais e técnicas de Portugal:

### A. Fonte e Descrição dos Dados

O conjunto de dados utilizado neste estudo foi facultado pela GNR e compreende todos os acidentes de viação registados entre 2019 e 2023 nas vias sob a jurisdição da GNR, abrangendo aproximadamente 94% do território nacional de Portugal [7]. Cada registo inclui variáveis contextuais e situacionais, tais como a data, a hora, a localização, as condições meteorológicas, o pavimento da via, as condições de iluminação, o tipo de acidente e a gravidade do mesmo. Após o pré-processamento, o conjunto de dados continha aproximadamente 330 000 entradas válidas. Os acidentes graves (vítimas mortais ou feridos graves) representavam menos de 5% de todos os registos, refletindo o desequilíbrio natural que é típico dos dados de acidentes do mundo real.

A qualidade dos dados poderá ter sido afetada durante a pandemia da COVID-19 (2020–2021), período em que as restrições de mobilidade causaram uma redução anormal nos acidentes registados [17]. Para mitigar estes efeitos, os registos inconsistentes ou incompletos foram removidos e foram aplicadas técnicas de normalização para reduzir a influência das irregularidades temporais.

### B. Pré-processamento de Dados e Engenharia de Características

Antes do treino dos modelos, foram aplicadas várias etapas de pré-processamento para garantir a qualidade dos dados e a compatibilidade com os algoritmos de aprendizagem automática. Os valores em falta (*missing values*) foram tratados por imputação (média ou moda) ou por remoção, nos casos em que a ausência de dados era insignificante. As colunas irrelevantes ou redundantes foram eliminadas para reduzir o ruído e a dimensionalidade.

As variáveis categóricas foram transformadas em representações numéricas através de codificação *One-hot* (*One-hot encoding*), evitando relações ordinais artificiais que pudessem induzir em erro o processo de aprendizagem [10]. Por exemplo, uma variável  $x$  com as categorias  $S = \{a, b, c\}$  seria codificada como  $(1, 0, 0)$ ,  $(0, 1, 0)$  e  $(0, 0, 1)$ , respetivamente. A informação temporal foi agregada ao nível mensal, extraindo apenas o ano e o mês ( $Date\_Year$ ,  $Date\_Month$ ) para preservar as tendências sazonais, reduzindo simultaneamente a dispersão (*sparsity*) das características. As características contínuas foram normalizadas conforme necessário para garantir uma contribuição proporcional durante o treino. Por fim, o conjunto de dados foi dividido em subconjuntos de treino e de teste para uma avaliação de desempenho imparcial.

A estrutura metodológica global está ilustrada na Fig. 1.




Figure 1. Methodological framework for accident severity prediction.

### C. Abordagem ao Desequilíbrio de Classes

Os conjuntos de dados de acidentes de viação são inerentemente desequilibrados, sendo que os acidentes graves constituem apenas uma pequena fração do total de registos. Para melhorar a sensibilidade do modelo aos casos críticos, foram utilizadas três estratégias: Ponderação de Classes (*Class Weighting*), Técnica de Sobreamostragem Sintética da Classe Minoritária (*Synthetic Minority Oversampling Technique - SMOTE*) e Subamostragem Aleatória (*Random Undersampling - RUS*).

1) *Ponderação de Classes*: A ponderação de classes ajusta a função de perda (*loss function*) para penalizar a classificação incorreta das classes minoritárias. Os pesos para cada classe foram calculados de forma inversamente proporcional às frequências das próprias classes:

$$w_i = \left(\frac{N}{n_i}\right)^\alpha \quad (1)$$

onde  $w_i$  é o peso para a classe  $i$ ,  $N$  é o número total de amostras,  $n_i$  é o número de amostras na classe  $i$ , e  $\alpha = 0,35$  controla a magnitude dos pesos. Esta abordagem modera a ponderação padrão por frequência inversa [18].

2) *SMOTE e Subamostragem Aleatória*: O SMOTE gera amostras sintéticas da classe minoritária através de interpolação, aumentando a sua representação no conjunto de dados de treino [19]. Em contrapartida, a RUS reduz as amostras da classe maioritária até que as classes estejam equilibradas. Estes métodos complementam a ponderação de

classes e melhoram a aprendizagem do modelo em eventos escassos e críticos.

### D. Arquiteturas dos Modelos

Foram avaliados quatro modelos de aprendizagem automática: Florestas Aleatórias (*RF*), XGBoost, *MLP* e *DNNs*.

O RF é um *ensemble* (combinação) de árvores de decisão que reduz o sobreajustamento (*overfitting*) e fornece medidas de importância das características, auxiliando na interpretabilidade [8], [20], [21]. O XGBoost introduz regularização e paralelização para um *gradient boosting* eficiente [22]. O MLP é uma rede neuronal direta (*feed-forward*) capaz de modelar relações não lineares complexas, enquanto as DNNs expandem os MLPs com camadas adicionais para extrair representações hierárquicas de características [3], [23]. Os modelos RF e XGBoost foram selecionados pela sua interpretabilidade e robustez em conjuntos de dados tabulares e desequilibrados; o MLP e a DNN foram incluídos para explorar o potencial da aprendizagem profunda na identificação de padrões complexos.

### E. Métricas de Avaliação

O desempenho dos modelos foi avaliado recorrendo à Precisão (*Precision*), Sensibilidade (*Recall*), Pontuação F1 (*F1-Score*) e Média Geométrica (*G-Mean*), as quais são adequadas para conjuntos de dados desequilibrados.

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Sensibilidade} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{Especificidade} = \frac{TN}{TN + FP} \quad (4)$$

$$\text{F1-Score} = 2 \cdot \frac{\text{Precisão} \cdot \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}} \quad (5)$$

$$\text{G-mean} = \sqrt{\text{Sensibilidade} \cdot \text{Especificidade}} \quad (6)$$

A exatidão (*Accuracy*) não foi utilizada devido à sua natureza enganosa em conjuntos de dados desequilibrados. As matrizes de confusão foram analisadas para avaliar o desempenho específico de cada classe, prestando especial atenção aos falsos negativos, os quais têm implicações operacionais críticas.

## IV. RESULTADOS E DISCUSSÃO

Esta secção apresenta os principais resultados obtidos a partir da análise do conjunto de dados de acidentes da GNR (2019–2023) e da avaliação dos modelos de aprendizagem automática e de aprendizagem profunda para a previsão da gravidade dos acidentes. A discussão foca-se no desempenho dos modelos, no impacto do equilíbrio de classes e nas implicações para a tomada de decisão operacional.



Table II  
MÉTRICAS DE DESEMPENHO ENTRE OS MODELOS E TÉCNICAS DE EQUILÍBRIO

Modelo	Dados	G-Mean	F1-Score	Sensibilidade
RF	Original	0,11	0,49	0,50
	Weighted	0,09	0,49	0,50
	<b>RUS</b>	<b>0,53</b>	0,47	<b>0,58</b>
	SMOTE	0,15	0,51	0,50
XGBoost	Original	0,12	0,50	0,51
	Weighted	0,21	0,52	0,52
	<b>RUS</b>	<b>0,54</b>	0,47	<b>0,59</b>
	SMOTE	0,17	0,51	0,51
MLP	Original	0,00	0,49	0,50
	Weighted	0,54	0,50	0,59
	RUS	0,24	0,49	0,54
	SMOTE	0,34	0,52	0,53
DNN	Original	0,05	0,49	0,50
	<b>Weighted</b>	<b>0,53</b>	0,50	<b>0,60</b>
	RUS	0,51	0,48	0,59
	SMOTE	0,35	0,53	0,54

ponderação de classes, demonstrando uma maior sensibilidade à classe minoritária e um melhor equilíbrio global entre a sensibilidade e a especificidade.

A ponderação de classes provou ser a estratégia mais eficaz, uma vez que penaliza diretamente as classificações incorretas dos acidentes graves, sem descartar dados nem gerar dados sintéticos. Em contrapartida, o SMOTE melhorou a sensibilidade à custa de um maior número de falsos positivos, e a RUS melhorou a deteção da classe minoritária, mas reduziu a generalização devido à perda de dados.

As condições de iluminação surgiram como uma característica particularmente influente, reforçando as conclusões anteriores de que os ambientes com visibilidade reduzida contribuem significativamente para desfechos de acidentes graves.

A DNN com ponderação de classes alcançou o melhor desempenho (Sensibilidade = 0,60, *G-Mean* = 0,53), seguida de perto pelo MLP (*G-Mean* = 0,54). Estes resultados confirmam que os modelos de aprendizagem profunda são mais adequados para captar relações não lineares em conjuntos de dados complexos e desequilibrados. Apesar das melhorias, a sensibilidade para acidentes graves permaneceu abaixo de 0,60, indicando que um maior enriquecimento dos dados, como a incorporação de variáveis contextuais ou em tempo real, aumentaria a exatidão preditiva.

No geral, as conclusões demonstram que a ponderação de classes é o método de equilíbrio mais eficaz e que os modelos de aprendizagem profunda, particularmente as DNNs, oferecem o melhor potencial para apoiar estratégias proativas de prevenção de acidentes e de atribuição de recursos baseadas em dados.

## V. CONCLUSÃO

Este estudo abordou a crescente necessidade de abordagens baseadas em dados para a segurança rodoviária, através do desenvolvimento e da comparação de modelos de aprendizagem automática (*machine learning* - ML) e de aprendizagem profunda (*deep learning* - DL) para prever a gravidade dos acidentes de viação, recorrendo a dados operacionais reais da Guarda Nacional Republicana (GNR). A análise demonstrou que a integração de análise preditiva pode apoiar uma atribuição de recursos mais eficaz e intervenções preventivas mais eficientes.

Entre os modelos testados, RF, XGBoost, MLP e DNNs, nenhum algoritmo se revelou universalmente superior. No entanto, os modelos de DL, particularmente as DNNs, demonstraram uma maior capacidade para captar padrões complexos e não lineares quando combinados com estratégias adequadas de equilíbrio de classes. A ponderação de classes surgiu como a técnica mais eficaz para lidar com o forte desequilíbrio de classes inerente ao conjunto de dados.

A análise de características revelou que as condições de iluminação são um dos principais fatores determinantes da gravidade dos acidentes, enfatizando a importância operacional de melhorar a iluminação pública, aumentar a visibilidade das patrulhas e priorizar ações preventivas durante o período noturno e em condições meteorológicas adversas. Estas conclusões oferecem perspetivas acionáveis para as forças de segurança, como a GNR e a PSP, apoiando a tomada de decisão fundamentada em dados e a gestão proativa da segurança.

Metodologicamente, este trabalho contribui para a investigação nacional ao combinar modelos tradicionais de ML e de DL com múltiplas estratégias de equilíbrio, utilizando dados policiais reais. A investigação futura deverá incorporar dados geoespaciais e em tempo real para melhorar a exatidão preditiva e desenvolver sistemas adaptativos para a avaliação dinâmica do risco de tráfego.

## REFERENCES

- [1] W. H. Organization, *Global Status Report on Road Safety 2018*. Geneva, Switzerland: World Health Organization, 2018, accessed on May 19, 2025. [Online]. Available: <https://www.who.int/publications-detail-redirect/9789241565684>
- [2] M. Megnidio-Tchoukouegno and J. A. Adedeji, "Machine learning for road traffic accident improvement and environmental resource management in the transportation sector," *Sustainability*, vol. 15, no. 3, p. 2014, 2023, accessed on May 19, 2025. [Online]. Available: <https://www.mdpi.com/2071-1050/15/3/2014>
- [3] Z. Jin and B. Noh, "From prediction to prevention: Leveraging deep learning in traffic accident prediction systems," *Electronics*, vol. 12, no. 20, p. 4335, 2023, accessed on May 19, 2025. [Online]. Available: <https://www.mdpi.com/2079-9292/12/20/4335>
- [4] J. Siswanto, A. Negara Syaban, and Hariyani, "Artificial intelligence in road traffic accident prediction," *Jambura Journal of Informatics*, vol. 5, no. 2, pp. 77–90, 2023, accessed on May 19, 2025. [Online]. Available: <https://ejurnal.ung.ac.id/index.php/jji/article/view/22037/0>
- [5] S. Mičić, R. Vuković, M. Džidić, and G. Amidžić, "Statistical models for predicting traffic accidents on rural roads," *Journal of Transportation Safety*, vol. 10, no. 4, pp. 45–59, 2023.
- [6] L. J. C. Rasteiro, "O dispositivo territorial da gnr: A importância do posto territorial na capacidade de intervenção junto das populações: O caso do distrito da guarda," Master's thesis, Universidade da Beira Interior, Covilhã, Portugal, 2021.
- [7] A. Dias, "Riscos em contexto operacional e a sua perceção na gnr," 2024.

- [8] M. Yan and Y. Shen, "Traffic accident severity prediction based on random forest." *Sustainability*, vol. 14, no. 3, p. 1729, 2022, accessed on May 19, 2025. [Online]. Available: <https://www.mdpi.com/2071-1050/14/3/1729>
- [9] T. Bokaba, W. Doorsamy, and B. S. Paul, "Comparative study of machine learning classifiers for modelling road traffic accidents," *Applied Sciences*, vol. 12, no. 2, p. 828, 2022, accessed on May 19, 2025. [Online]. Available: <https://www.mdpi.com/2076-3417/12/2/828>
- [10] D. Dias, "Predição do risco de acidente rodoviário através de métodos de mineração de dados," Master's thesis, Instituto Superior Técnico, Lisboa, Portugal, 2022. [Online]. Available: <https://fenix.tecnico.ulisboa.pt/cursos/mec21/dissertacao/1128253548923106>
- [11] F. Chen, X. Q. Liu, and J. J. e. a. Yang, "Traffic accident severity prediction based on an enhanced mscpo-xgboost hybrid model," *Scientific Reports*, vol. 15, p. 25729, 2025, accessed on October 6, 2025. [Online]. Available: <https://www.nature.com/articles/s41598-025-00797-7>
- [12] S. e. a. Somvanshi, "Predicting electric vehicle crash severity with pretrained transformers (tabpfn) and mamba-based models," *arXiv*, 2025, accessed on October 2, 2025. [Online]. Available: <https://arxiv.org/abs/2509.11449v1>
- [13] J. e. a. Chen, "A novel generative adversarial network for improving crash severity prediction," *Transportation Research Part C: Emerging Technologies*, 2024, accessed on October 2, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0968090X24001633>
- [14] S. Bazarnovi and A. K. Mohammadian, "Addressing imbalanced data in predicting injury severity after traffic crashes: A comparative analysis of machine learning models," *Procedia Computer Science*, vol. 238, pp. 24–31, 2024.
- [15] K. e. a. Aziz, "An interpretable dynamic ensemble selection multiclass classifier for crash severity prediction," *Scientific Reports*, 2025, accessed on October 2, 2025. [Online]. Available: <https://www.nature.com/articles/s41598-025-08935-x>
- [16] P. Infante, G. Jacinto, A. Afonso, L. Rego, V. Nogueira, P. Quaresma, J. Saias, D. Santos, P. Nogueira, M. Silva, R. Pisco Costa, P. Gois, and P. Rebelo Manuel, "Comparison of statistical and machine-learning models on road traffic accident severity classification," *Computers*, vol. 11, no. 5, p. 80, 2022, accessed on May 19, 2025. [Online]. Available: <https://www.mdpi.com/2073-431X/11/5/80>
- [17] Y. J. Yasin *et al.*, "Global impact of covid-19 pandemic on road traffic collisions," *World Journal of Emergency Surgery*, vol. 16, p. Article 95, 2021. [Online]. Available: <https://doi.org/10.1186/s13017-021-00395-8>
- [18] Y. Cui, M. Jia, T.-Y. Lin, Y. Song, and S. Belongie, "Class-balanced loss based on effective number of samples," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, pp. 9268–9277.
- [19] M. e. a. Zhang, "DI and clustering for imbalanced data," *J. Transp. Saf. Secur.*, 2025.
- [20] L. Breiman, "Machine learning, volume 45, number 1 - springerlink," *Machine Learning*, vol. 45, pp. 5–32, 10 2001.
- [21] G. Biau and E. Scornet, "A random forest guided tour," *Test*, vol. 25, no. 2, pp. 197–227, 2016, accessed on May 19, 2025. [Online]. Available: <https://link.springer.com/article/10.1007/s11749-016-0481-7>
- [22] T. Chen and C. Guestrin, "Xgboost: A scalable tree boosting system," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, 2016, pp. 785–794, accessed on October 2, 2025. [Online]. Available: <https://dl.acm.org/doi/10.1145/2939672.2939785>
- [23] F. e. a. Alanazi, "Comparative evaluation of deep learning and traditional approaches for driver injury pattern recognition," *Scientific Reports*, 2025, accessed on October 6, 2025. [Online]. Available: <https://www.nature.com/articles/s41598-025-13484-4>