

APLICAÇÃO DE MODELOS PREDITIVOS DE ACIDENTES RODOVIÁRIOS EM AUTOESTRADAS

O caso da A25

CAROLINE MARIA CASTRO MACHADO

Dissertação submetida para satisfação parcial dos requisitos do grau de
**MESTRE EM ENGENHARIA CIVIL — ESPECIALIZAÇÃO EM PLANEAMENTO DO TERRITÓRIO E
TRANSPORTES**

Orientador: Professor Doutor António José Fidalgo do Couto

JULHO DE 2022

MESTRADO EM ENGENHARIA CIVIL 2021/2022

DEPARTAMENTO DE ENGENHARIA CIVIL

Tel. +351-22-508 1901

✉ m.ec@fe.up.pt

Editado por

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO

Rua Dr. Roberto Frias

4200-465 PORTO

Portugal

Tel. +351-22-508 1400

✉ feup@fe.up.pt

🌐 <http://www.fe.up.pt>

Reproduções parciais deste documento serão autorizadas na condição que seja mencionado o Autor e feita referência a *Mestrado em Engenharia Civil - 2021/2022 - Departamento de Engenharia Civil, Faculdade de Engenharia da Universidade do Porto, Porto, Portugal, 2022*.

As opiniões e informações incluídas neste documento representam unicamente o ponto de vista do respetivo Autor, não podendo o Editor aceitar qualquer responsabilidade legal ou outra em relação a erros ou omissões que possam existir.

Este documento foi produzido a partir de versão eletrónica fornecida pelo respetivo Autor.

À minha família e amigos

*Sozinha não posso mudar o mundo, mas posso atirar uma pedra através das águas e criar
muitas ondulações*

Madre Teresa de Calcutá

AGRADECIMENTOS

Dá-me imensa alegria olhar para trás e lembrar de todos que fizeram parte da jornada que me trouxe até aqui.

Primeiramente, agradeço à Deus por estar sempre ao meu lado.

Agradeço à minha família pelo eterno carinho e por sempre me apoiarem, mesmo que isso implicasse minha mudança para terras longínquas... A saudade é grande, mas é recompensador saber que estão orgulhosos dos caminhos que trilhei.

À Karina e Josedna, duas mulheres incríveis que tenho o prazer de ter como mãe e avó. A força que vocês me ensinaram a ter, e o suporte dado foram essenciais para que eu conseguisse sair do conforto de casa para estudar em um país inteiramente desconhecido.

Ao meu pai Francisco, meu avô José Olímpio e a meu avô de coração Dirceu, os principais torcedores do meu sucesso profissional.

À minha irmã Aline, e aos meus irmãosinhos Vitor e Benjamin. Meu coração sempre fica em pedaços ao lembrar da nossa distância, mas obrigada por compreenderem o motivo da minha vinda para Portugal (mesmo que parcialmente).

Um agradecimento especial ao meu orientador Professor Doutor António Couto pelo apoio e disponibilidade para orientar meu trabalho de dissertação, e à Professora Doutora Sara Ferreira, quem me inspirou para a realização desta dissertação, e cujo contributo com seus conhecimentos e dedicação também foram fundamentais para a realização deste trabalho.

Ao Engº João Neves, obrigada pela oportunidade de realizar a dissertação em ambiente empresarial na Ascendi. Seu engajamento na Segurança Rodoviária e partilha de experiência, somados à confiança depositada em mim, foram grandes motivadores para me dedicar ao máximo à dissertação e ao estágio e com isso crescer como profissional.

Aos profissionais da Ascendi, por me receberem de braços abertos e partilharem momentos que tornaram minha primeira experiência profissional inesquecível e cheia de aprendizados. Um agradecimento especial à Engª Telma Silva, ao Engº Carlos de Oliveira e ao Engº Tiago Jorge, pelo acolhimento e acompanhamento prestados ao longo do meu estágio.

À minhas amigas Maria Carolina, Gabriela e Sarah, que deixei no Brasil, mas que seguem sempre ao meu lado, apesar da distância.

Às amigas que fiz durante o Erasmus, Paula, Léane e Heni, com quem em pouco tempo vivi inúmeras aventuras e ganhei inúmeras histórias para a vida toda.

Por fim e não menos importante, ao meu companheiro Gabriel pela parceria incrível e suporte que me deu nesta reta final do curso, e aos amigos que a FEUP me presenteou e que se tornaram minha família em Portugal. Um agradecimento especial ao Daniel, à Bianca, à Suelaine e ao Marcelo, que estiveram presentes durante todos esses 5 anos e viveram comigo todos os altos e baixos de se estudar fora do país (e engenharia). Obrigada pelas gargalhadas, pelas loucuras, companhia diária na FEUP e fora dela, e também pela paciência nos momentos mais estressantes.

A todos vocês que contribuíram direta e indiretamente para a realização de um sonho, e tornaram esta jornada muito mais prazerosa, obrigada.

RESUMO

Os acidentes rodoviários são um grande problema de saúde pública mundial. Embora a União Europeia (UE) tenha obtido considerável progresso em tornar suas vias mais seguras, tem-se notado uma estagnação na redução no número de mortos nos últimos anos (ETSC, 2021). Face à essa tendência e de forma a atingir a meta de zero mortos na UE até 2050, são necessárias novas abordagens como a do Sistema Seguro (Comissão Europeia, 2020), que recomenda a adoção de medidas proativas na segurança rodoviária. Neste contexto, os modelos de previsão de acidentes (MPAs) são ferramentas eficientes de suporte à decisão, uma vez que são baseados em análises robustas de todo o sistema que apresenta risco, permitindo minimizar as consequências do erro humano, ao invés de definir locais para tratamento com base unicamente no histórico de acidentes.

Neste trabalho, desenvolveram-se modelos de previsão de frequência de acidentes, para 158 km da autoestrada portuguesa A25, operada pela Ascendi, com dados dos anos de 2015 a 2021. Utilizaram-se modelos lineares generalizados, e as distribuições de Poisson e Binomial Negativa foram as que melhor se ajustaram aos dados dos acidentes totais e acidentes com vítimas, respetivamente. A segmentação da autoestrada, importante para a construção da base de dados, fez-se pela divisão em segmentos homogêneos nas suas características viárias. A validação consistiu em avaliar a qualidade de ajuste dos modelos, e também em testar sua capacidade de previsão. No último caso, os modelos foram calibrados novamente, com dados de 2015 a 2019, e os restantes anos (2020 e 2021) foram usados para previsão.

Com os resultados obtidos, foi possível avaliar influência de fatores geométricos e operacionais das vias na ocorrência dos acidentes, e também foi feita uma aplicação prática que utilizou da projeção do tráfego de 2023 para estimar os acidentes no mesmo ano. Com isso, fez-se a identificação de locais de risco, seguida da comparação entre duas abordagens distintas na seleção dos locais para tratamento. Espera-se que os modelos desenvolvidos possam ser utilizados e expandidos para outras autoestradas, apoiando a implementação do Plano de Ação de Segurança Rodoviária da operadora.

PALAVRAS-CHAVE: modelos de previsão de acidentes rodoviários, fatores de risco, segmentação, segurança rodoviária, Sistema Seguro.

ABSTRACT

Road accidents are a major public health problem in the world. Although in the EU there has been a great progress in making the roads safer, it is notable that the reduction in road deaths over the last years is stagnating (ETSC, 2021). Considering this trend and in order to reach the ambitious target of zero deaths in EU roads by 2050, new approaches are required, such as the Safe System (European Comission, 2020), which recommends the adoption of proactive measures for road safety. In this context, accident prediction models are proven to be efficient tools to support the decision making by road operators, allowing to reduce the consequences of human error, once they are based on robust analysis of the whole system that presents risk, rather than simply defining sites for treatment based on accident history.

In this work, accident frequency prediction models were developed for 158 km of the Portuguese A25 motorway, operated by Ascendi, with data from 2015 to 2021. Generalized linear models were used, and Poisson and Negative Binomial distribution were the ones that better fitted data for total accidents and injury accidents, respectively. Network segmentation is an important step in the database construction and was made by the division of homogeneous segments in its road characteristics. Model validation consisted in evaluating the two models' goodness-of-fit, and in testing their predictive capacity. In the last case, models had to be calibrated again, with data from 2015 to 2019, and the remaining years (2020 e 2021) were used for prediction.

With the results obtained, it was possible to evaluate the effect of road geometric and operational factors on accident occurrence, and a practical application was developed using 2023's traffic projection to estimate the accidents in the same year. Then, an identification of risk sites was made, followed by the comparison between two distinct approaches in the selection of sites for treatment. It is expected that the developed accident prediction models can be further used and expanded to other motorways and therefore to continue to support the implementation of the operator's Road Safety Action Plan.

KEYWORDS: accident prediction models, risk factors, segmentation, road safety, Safe System.

ÍNDICE GERAL

AGRADECIMENTOS	i
RESUMO	iii
ABSTRACT	iv
1 INTRODUÇÃO	1
1.1. PREÂMBULO	1
1.2. OBJETIVOS	4
1.3. ESTRUTURA DA DISSERTAÇÃO	4
2 MODELOS DE PREVISÃO DE ACIDENTES	5
2.1. OS MODELOS PREDITIVOS E A ABORDAGEM DO SISTEMA SEGURO	5
2.2. A MODELAÇÃO NA SEGURANÇA RODOVIÁRIA	7
2.3. MODELOS DE FREQUÊNCIA DE ACIDENTES	8
2.3.1. FORMA FUNCIONAL DO MODELO.....	9
2.3.2. ESTIMATIVA DOS PARÂMETROS DA FUNÇÃO	12
2.3.3. VALIDAÇÃO DOS MODELOS	13
2.3.4. VARIÁVEIS INDEPENDENTES	15
2.4. SEGMENTAÇÃO DAS VIAS	16
2.4.1. EXTENSÃO DOS SEGMENTOS	16
2.4.2. SEGMENTAÇÃO COM EXTENSÕES VARIÁVEIS	17
3 CASO DE ESTUDO	18
3.1. METODOLOGIA.....	18
3.2. DEFINIÇÃO DA ÁREA DE ESTUDO.....	20
3.2.1. SEGURANÇA RODOVIÁRIA NA REDE ASCENDI E EXPERIÊNCIA COM MPA'S.....	20
3.2.2. DADOS DA ASCENDI.....	22
3.2.3. AUTOESTRADA A25	24
3.3. RECOLHA, TRATAMENTO DOS DADOS E SELEÇÃO DAS VARIÁVEIS	27
3.3.1. RECOLHA E TRATAMENTO DOS DADOS	27
3.3.2. SELEÇÃO DAS VARIÁVEIS	30
3.4. SEGMENTAÇÃO DA AUTOESTRADA A25.....	32
3.4.1. FASE 1 – DIVISÃO EM SEGMENTOS HOMOGÊNEOS COM BASE NA GEOMETRIA DA AUTOESTRADA.....	32
3.4.2. FASE 2 – AFETAÇÃO DAS VARIÁVEIS DO MODELO AOS SEUS RESPECTIVOS SEGMENTOS	34
3.6. MODELAÇÃO	35

3.7. VALIDAÇÃO DOS MODELOS	38
4 RESULTADOS E ANÁLISES	40
4.1. MODELO DE PREVISÃO DE FREQUÊNCIA DE ACIDENTES TOTAIS (2015-2021)	41
4.1.1. CONSTRUÇÃO DO MODELO	41
4.1.2. VALIDAÇÃO REPLICATIVA	43
4.1.3. INTERPRETAÇÃO DO EFEITO DAS VARIÁVEIS EXPLICATIVAS NOS ACIDENTES TOTAIS	44
4.2. MODELO DE PREVISÃO DE FREQUÊNCIA DE ACIDENTES COM VÍTIMAS (2015-2021)	46
4.2.1. CONSTRUÇÃO DO MODELO	46
4.2.2. VALIDAÇÃO REPLICATIVA.....	48
4.2.3. INTERPRETAÇÃO DO EFEITO DAS VARIÁVEIS EXPLICATIVAS NOS ACIDENTES COM VÍTIMAS	50
4.3. AVALIAÇÃO DA CAPACIDADE PREDITIVA DOS MODELOS	51
4.3.1. MODELO DE FREQUÊNCIA DE ACIDENTES TOTAIS (2015-2019)	51
4.3.2. MODELO DE FREQUÊNCIA DE ACIDENTES COM VÍTIMAS (2015-2019).....	55
5 APLICAÇÃO DO MODELO	57
5.1. PREVISÃO DOS ACIDENTES TOTAIS PARA UM CENÁRIO HIPOTÉTICO	57
5.1.1. ANÁLISE DOS ACIDENTES NOS SUBLANÇOS EM 2023.....	59
5.1.2. CONSIDERAÇÕES FINAIS	62
6 CONCLUSÕES.....	63
REFERÊNCIAS BIBLIOGRÁFICAS.....	68
ANEXO A – TMDA [VEÍCULOS/DIA] E PERCENTAGEM DE PESADOS NA BLA (2015 A 2021)	73
ANEXO B – MATRIZ DE CORRELAÇÃO ENTRE AS VARIÁVEIS INDEPENDENTES.....	77
ANEXO B.1 – MATRIZ DE CORRELAÇÃO PARA AS VARIÁVEIS EXPLICATIVAS DOS ACIDENTES TOTAIS	78
ANEXO B.2 – MATRIZ DE CORRELAÇÃO PARA AS VARIÁVEIS EXPLICATIVAS DOS ACIDENTES COM VÍTIMAS	79
ANEXO C – RESULTADOS DA MODELAGEM NO SOFTWARE SPSS	80
ANEXO C.1 – MODELO DE FREQUÊNCIA DE ACIDENTES TOTAIS (2015-2021)	81
ANEXO C.2. – MODELO DE FREQUÊNCIA DE ACIDENTES COM VÍTIMAS (2015-2021)	87
ANEXO C.3 – MODELO DE FREQUÊNCIA DE ACIDENTES TOTAIS (2015-2019)	91
ANEXO C.4 – MODELO DE FREQUÊNCIA DE ACIDENTES COM VÍTIMAS (2015-2019)	94
ANEXO D – COMPARAÇÃO ENTRE OS MODELOS COM DADOS DE 7 E DE 5 ANOS	96
ANEXO D.1. ACIDENTES TOTAIS	97
ANEXO D.1.1. RESÍDUOS ACUMULADOS ACIDENTES TOTAIS (2015-2019) PARA O TMDA – PREVISÃO DO MODELO 7 ANOS.....	97

ANEXO D.1.2. RESÍDUOS ACUMULADOS ACIDENTES TOTAIS (2015-2019) PARA O COMPRIMENTO – PREVISÃO DO MODELO 7 ANOS.....	97
ANEXO D.1.3. RESÍDUOS ACUMULADOS ACIDENTES TOTAIS (2015-2019) PARA O TMDA – PREVISÃO DO MODELO 5 ANOS.....	98
D.1.4. RESÍDUOS ACUMULADOS ACIDENTES TOTAIS (2015-2019) PARA O COMPRIMENTO – PREVISÃO DO MODELO 5 ANOS.....	98
D.2. ACIDENTES COM VÍTIMAS	99
D.2.1. RESÍDUOS ACUMULADOS ACIDENTES COM VÍTIMAS (2015-2019) PARA O TMDA – PREVISÃO DO MODELO 7 ANOS.....	99
D.2.2. RESÍDUOS ACUMULADOS ACIDENTES COM VÍTIMAS (2015-2019) PARA O COMPRIMENTO – PREVISÃO DO MODELO 7 ANOS.....	99
D.2.3 RESÍDUOS ACUMULADOS ACIDENTES COM VÍTIMAS (2015-2019) PARA O TMDA – PREVISÃO DO MODELO 5 ANOS.....	100
D.2.4. RESÍDUOS ACUMULADOS ACIDENTES COM VÍTIMAS (2015-2019) PARA O COMPRIMENTO – PREVISÃO DO MODELO 5 ANOS.....	100
ANEXO E – RESULTADOS DA APLICAÇÃO DO MODELO DE ACIDENTES TOTAIS	101
ANEXO E.1 – IDENTIFICAÇÃO DOS SUBLANÇOS DA A25 PARA MELHORIA DA SR. MEDIDA PROATIVA VS. REATIVA.....	102
ANEXO E.2 – SUBLANÇOS COM MAIOR MÉDIA DE ACIDENTES TOTAIS OBSERVADA ENTRE 2015 E 2021 ...	104

ÍNDICE DE FIGURAS

Fig. 1– Redução das mortes nas estradas em 2020 em relação a 2010 nos países participantes do estudo. Fonte: European Transport Safety Council (ETSC), 2021.	2
Fig. 2 – Redução do número de mortes nos países membros da UE de 2010 a 2020 e comparação com o objetivo estipulado. Fonte: European Transport Safety Council (ETSC), 2021.	2
Fig. 3 – Princípios, elementos centrais e áreas de ação da abordagem SS. Fonte: https://visionzerochallenge.org/vision-zero	3
Fig. 4 – Variação a curto prazo na frequência de acidentes num determinado local. Fonte: AASHTO, 2010.	5
Fig. 5 – Comparação da diferença entre a eficácia percebida e real eficácia de um tratamento, devido ao enviesamento to FRM. Fonte: AASHTO, 2010.	6
Fig. 6 – Influência dos elementos do sistema de tráfego nos acidentes rodoviários. Fonte: Cardoso, J.; Gomes, S. (2002).	7
Fig. 7 – Estrutura do trabalho.	19
Fig. 8 – Rede Ascendi. Fonte: Anuário de Segurança Rodoviária, 2021.	20
Fig. 9 – Acidentes do ano corrente ilustrados na plataforma SIG da Ascendi. Fonte: Ascendi (2022).	22
Fig. 10 – Comparação entre o número de acidentes e o TMDA na rede Ascendi (2015-2021).	23
Fig. 11 – Número de feridos ligeiros, feridos graves e mortos na rede Ascendi (2015-2021).	23
Fig. 12 – Mapa da autoestrada A25 (BLA). Fonte: Ascendi (2021).	24
Fig. 13 – Comparação entre o número de acidentes e o TMDA na A25 Costa de Prata (2015-2021).	25
Fig. 14 – Comparação entre o número de acidentes e o TMDA na A25 Beiras Litoral e Alta (2015-2021).	26
Fig. 15 – Número de feridos ligeiros, feridos graves e mortos na A25 CP (2015-2021).	26
Fig. 16 – Número de feridos ligeiros, feridos graves e mortos na BLA (2015-2021).	26
Fig. 17 – Comparação da Sinistralidade/Extensão da A25 CP vs BLA.	27
Fig. 18 – Comparação entre o TMDA na A25 CP e BLA.	29
Fig. 19 – Representação dos três segmentos do Quadro 4.	34
Fig. 20 – Gráfico dos resíduos acumulados dos acidentes totais (2015-2021) para a variável TMDA [veíc./dia] – modelo 7 anos.	43
Fig. 21 – Gráfico dos resíduos acumulados dos acidentes totais (2015-2021) para a variável comprimento [m] – modelo 7 anos.	43
Fig. 22 – Gráfico dos resíduos acumulados dos acidentes com vítimas (2015-2021) para a variável TMDA [veíc./dia] – modelo 7 anos.	49
Fig. 23 – Gráfico dos resíduos acumulados dos acidentes com vítimas (2015-2021) para a variável comprimento [m] – modelo 7 anos.	49

Fig. 24 – Gráfico dos resíduos acumulados dos acidentes totais (2020) para a variável TMDA [veíc./dia] – modelo 5 anos.	53
Fig. 25 – Resíduos Acumulados dos acidentes totais (2020) para a variável comprimento [m] – modelo 5 anos.	53
Fig. 26 – Resíduos Acumulados da variável TMDA para acidentes Totais (2021) – modelo 5 anos... ..	54
Fig. 27 – Resíduos Acumulados da variável Comprimento para acidentes Totais (2021) – modelo 5 anos.	54
Fig. 28 – Análise da evolução (projetada) do TMDA em 2023, em relação à média dos anos 2015-2021, para o sentido crescente da A25.	58
Fig. 29 – Análise da evolução (projetada) do TMDA em 2023, em relação à média dos anos 2015-2021, para o sentido decrescente da A25.	58
Fig. 30 – Comparação entre os acidentes totais previstos para o ano 2023, por sublanço, e a média histórica (2015-2021), sentido crescente.	59
Fig. 31 – Comparação entre os acidentes totais previstos para o ano 2023, por sublanço, e a média histórica (2015-2021), sentido decrescente.	60
Fig. 32 – Etapas recomendadas para atualização dos MPAs.	62
Fig. 33 – Síntese do trabalho.	66

ÍNDICE DE QUADROS

Quadro 1 – Modelos preditivos criados para as autoestradas da Ascendi.....	21
Quadro 2 – Sublanços da A25 (BLA) e seus respetivos PK de início e fim.....	28
Quadro 3 – Dados dos acidentes em plena via de 2015 a 2021, por Ano e Sentido, na BLA.	30
Quadro 4 – Amostra da folha de cálculo resultante da 1ª fase da segmentação.	33
Quadro 5 – Base de dados referente ao trecho do sublanço Mangualde – Chãs de Tavares, sentido crescente representado no Quadro 4.	35
Quadro 6 – Variáveis inicialmente consideradas para o processo de modelação.	35
Quadro 7 – estatística descritiva das variáveis dependentes.	36
Quadro 8 – estatística descritiva das variáveis independentes.	36
Quadro 9 – Medidas de desempenho do modelo de acidentes totais (7 anos).	41
Quadro 10 – Resultados das estimativas do modelo de Poisson para o MPA totais (2015-2021). Erro! Marcador não definido.	
Quadro 11 – Elasticidade das variáveis contínuas e aumento da probabilidade de acidentes para aumentos de 10% – MPA Acidentes Totais (2015-2021).	44
Quadro 12 – Pseudo-Elasticidade das variáveis dummy – Acidentes Totais.....	45
Quadro 13 – Medidas de desempenho do MPA com vítimas (2015-2021).	47
Quadro 14 – Resultados das estimativas do modelo Binomial Negativo para Acidentes com Vítimas (7 anos).	48
Quadro 15 – Elasticidade de aumentos de 10% nas variáveis contínuas na probabilidade de acidentes – MPA com vítimas (2015-2021).	50
Quadro 16 – Pseudo-Elasticidade das variáveis dummy – Acidentes com Vítimas.....	50
Quadro 17 – Resultados das estimativas do modelo de Poisson para acidentes totais (5 anos).	52
Quadro 18 – Resultados das estimativas do modelo Binomial Negativo para acidentes com vítimas (5 anos).	55
Quadro 19 – Identificação dos sublanços da A25 para melhoria da SR. Medida proativa vs. reativa.	61
Quadro 21 – Relações encontradas entre as características geométricas, de perfil transversal e operacionais da A25 (BLA) e os acidentes totais.	64
Quadro 22 – Relações encontradas entre as características geométricas, de perfil transversal e operacionais da A25 (BLA) e os acidentes com vítimas.....	64

SÍMBOLOS, ACRÓNIMOS E ABREVIATURAS

OMS – Organização Mundial da Saúde
ANSR – Autoridade Nacional de Segurança Rodoviária
SR – Segurança Rodoviária
UE – União Europeia
ETSC – *European Transport Safety Council*
SS – Sistema Seguro
ZAA – Zona de Acumulação de Acidentes
PASR – Plano de Ação de Segurança Rodoviária
FRM – Fenómeno de Regressão à Média
MPA – Modelo de Previsão de Acidentes
ML – *Machine Learning*
ANN – *Artificial Neural Networks*
HSM – *Highway Safety Manual*
TMDA – Tráfego Médio Diário Anual
MLG – Modelo Linear Generalizado
BN – Binomial Negativo
MCMC – Monte Carlo via Cadeias de Markov
AIC – Critério de Informação de Akaike
BIC – Critério de Informação Bayesiano
ANSR – Autoridade Nacional de Segurança Rodoviária
CURE – *CUmulative RESiduals*
BLA – Beiras Litoral e Alta
CP – Costa de Prata
SIG – Sistema de Informação Geográfica
PK – Ponto quilométrico

1

INTRODUÇÃO

1.1. PREÂMBULO

Os acidentes de viação são um grande problema de saúde pública mundial. Segundo a Organização Mundial da Saúde (OMS), anualmente ocorrem cerca de 1.3 milhões de acidentes rodoviários resultantes em vítimas fatais que poderiam ser prevenidos (OMS, 2021).

Para além dos danos físicos, emocionais e patrimoniais que podem prolongar-se para a vida toda dos indivíduos envolvidos num acidente e para aqueles que o rodeiam, os custos económicos e sociais dos acidentes para um país são avultados. Segundo a Autoridade Nacional de Segurança Rodoviária (ANSR), somente em Portugal em 2019, estes custos foram cerca de 6,4 milhões de Euros, representando 3,03% do PIB do país (ANSR, 2021).

Com a crescente procura pelo meio de transporte viário, a ocorrência de acidentes também tende a aumentar, e a redução da sinistralidade torna-se cada vez mais uma preocupação das autoridades que podem atuar em prol da segurança rodoviária (SR). Em sintonia com esta realidade, as Nações Unidas incluíram em 2015 a segurança rodoviária nos Objetivos de Desenvolvimento Sustentável (Nações Unidas, 2015), incrementando a importância da SR na agenda política. Entretanto ainda há muito a ser melhorado, mas os esforços que alguns países têm efetuado estão no caminho certo para a redução considerável da sinistralidade rodoviária.

As estradas na União Europeia (UE) destacam-se como umas das mais seguras do mundo, e países como Portugal têm sido bem-sucedidos em reduzir as mortes nas suas estradas. Entretanto, o objetivo estipulado pela UE de reduzir pela metade as mortes nas estradas entre 2010 e 2020 foi atingido apenas pela Noruega (membro apenas do Espaço Económico Europeu) e Grécia (European Transport Safety Council, 2021), como pode ser visto na Figura 1.




Fig. 1– Redução das mortes nas estradas em 2020 em relação a 2010 nos países participantes do estudo.

Fonte: European Transport Safety Council (ETSC), 2021.

* estimativas provisórias para 2020.

Na figura é possível ver que dos países da UE, a Grécia foi o único bem-sucedido na meta, seguido de Portugal, que, entretanto, não atingiu os 50% estipulados, porém conseguiu atingir valores melhores que média atingida pelos países envolvidos no estudo, de 37%.

O mesmo estudo ainda revelou que nos 3 primeiros anos após adoção da meta, o progresso nos países membros da UE foi mais relevante, com uma redução média de 18%, mas que em seguida estagnou-se (com exceção do ano de 2020, onde houveram medidas de restrição da circulação, e consequente redução do tráfego, devido à pandemia Covid-19), com uma redução média das mortes de apenas 6% entre 2013 e 2019 (ETSC, 2021).




Fig. 2 – Redução do número de mortes nos países membros da UE de 2010 a 2020 e comparação com o objetivo estipulado. Fonte: European Transport Safety Council (ETSC), 2021.

De modo a evitar que esta estagnação na redução das mortes continue, novas abordagens mostram-se importantes, como é o caso da abordagem do Sistema Seguro (SS) que serve de base para as estratégias de segurança rodoviária definidas para 2021-2030 pela UE, com o objetivo final de cumprir a “Visão Zero”, isto é, atingir zero mortos e feridos graves nas estradas europeias até 2050 (Comissão Europeia, 2020).

O Sistema Seguro parte do princípio de que as estradas devem perdoar o erro humano, assumido que a responsabilidade na segurança rodoviária não depende unicamente dos condutores, mas é partilhada com quem planeia e gere as estradas. Somado a isso, a abordagem do SS chama atenção para a necessidade da adoção de medidas mais proativas, combinadas com as tradicionais medidas reativas na detecção de locais perigosos para posterior tratamento (ANSR, 2020).




Fig. 3 – Princípios, elementos centrais e áreas de ação da abordagem SS. Fonte:

<https://visionzerochallenge.org/vision-zero>.

Neste contexto, os modelos preditivos de acidentes surgem como uma ferramenta que as empresas e instituições gestoras das estradas podem aplicar para a melhoria da concepção e operação das vias voltada para a redução da sinistralidade. Tais modelos auxiliam no entendimento dos fatores relacionados com a ocorrência dos acidentes e também permitem prever a redução dos acidentes caso alguma mudança seja realizada, normalmente a nível da infraestrutura viária.

Dentre algumas aplicações, e ao contrário das medidas reativas, os modelos preditivos permitem por meio de uma análise estatística robusta, classificar locais perigosos, como as Zonas de Acumulação de Acidentes (ZAAs) em locais que não são necessariamente os que mais registaram acidentes. Isto permite o estudo e tratamento dos locais de risco de acidentes antes mesmo da sua ocorrência. Como resultado, é possível atuar preventivamente na redução dos acidentes e na sua gravidade.

A utilização de modelos preditivos pode contribuir para medidas da segurança mais eficientes, uma vez que permitem estimar os efeitos de cada uma em termos de sinistralidade, contribuindo para uma alocação mais efetiva dos recursos financeiros.

Ressalta-se assim a importância do contributo das Entidades gestoras das estradas investirem no desafio global da redução da sinistralidade rodoviária, em prol da segurança dos seus clientes e da otimização dos seus investimentos.

1.2. OBJETIVOS

Este trabalho tem como objetivo o desenvolvimento, validação e aplicação de modelos de previsão de frequência de acidentes a uma autoestrada, a fim de contribuir com a segurança rodoviária na rede Ascendi, operadora da autoestrada estudada. Nomeadamente, espera-se, após a obtenção dos modelos, identificar os fatores viários relacionados aos acidentes e quantificar o seu efeito, além de utilizá-los para prever os acidentes em um cenário específico, para que os modelos sirvam como ferramenta de suporte à decisão.

Adicionalmente, de forma a facilitar e otimizar sua utilização e expandir a criação para outras autoestradas, procurou-se elucidar a transição entre a teoria e a prática no que toca à construção da base de dados, aplicação do modelo e sua atualização com dados dos anos que sucedem.

Estes modelos são métodos estatísticos robustos, que consideram diversas variáveis explicativas e dados de diversos anos, permitindo assim, avaliar o nível de segurança nas autoestradas de forma mais proactiva. Consequentemente, podem trazer resultados mais efetivos de redução da sinistralidade rodoviária, quando utilizadas combinados ou no lugar das tradicionais medidas reativas (baseadas nos registos de acidentes).

Este trabalho, em conjunto com a dissertação de Souza, S. (2021) e Ribeiro, J. (2021) está enquadrado no Plano de Ação de Segurança Rodoviária da Ascendi (PASR 2020-2023) como medidas a serem aplicadas antes dos acidentes ocorrerem, de forma a atingir a meta de redução anual dos acidentes estabelecida pela operadora.

1.3. ESTRUTURA DA DISSERTAÇÃO

Esta dissertação está estruturada em 6 capítulos:

- Capítulo 1: expõe o tema de estudo e âmbito em que está inserido, objetivos e estrutura da dissertação;
- Capítulo 2: apresenta a natureza dos acidentes rodoviários e a relevância de utilizar modelos de previsão para auxiliar a tomada de decisão na segurança rodoviária. Também descreve o estado da arte no processo da criação e validação dos modelos;
- Capítulo 3: enquadra o caso de estudo e a metodologia utilizada na construção da base de dados, modelagem e validação;
- Capítulo 4: apresenta os resultados e sua análise;
- Capítulo 5: desenvolve uma aplicação prática dos modelos e considerações finais para sua utilização;
- Capítulo 6: exhibe as principais conclusões, recomendações e perspectivas futuras.

2

MODELOS DE PREVISÃO DE ACIDENTES

2.1. OS MODELOS PREDITIVOS E A ABORDAGEM DO SISTEMA SEGURO

A fim de reduzir a sinistralidade rodoviária, as entidades gestoras muito comumente selecionam os locais de risco para tratamento, como as Zonas de Acumulação de Acidentes, com base nas contagens dos acidentes ocorridos no curto prazo. Esse método não considera os fatores que contribuíram para sua ocorrência, nem mesmo o Fenómeno de Regressão à Média (FRM), o que pode trazer resultados ineficientes, especialmente a longo prazo (Khodadadi, A. *et al.*, 2022).

Segundo o *Highway Safety Manual* (AASHTO, 2010), o FRM refere-se à flutuação da frequência de acidentes ao longo do tempo para um ponto de observação, inerente à natureza aleatória dos acidentes (Figura 4). Portanto, quando estudada essa frequência a curto prazo, é possível que o local esteja a registrar poucas ou muitas ocorrências devidas apenas à redução ou aumento da frequência acidentes oriundas do FRM, o que não corresponde à frequência típica daquele local a longo prazo. Sendo assim, caso seja tomado um período curto de tempo de análise para determinar os locais que merecem tratamento, tais medidas tornam-se menos efetivas, pois por exemplo, parte da redução dos acidentes observada após o tratamento pode ser na verdade devida da redução natural do FRM (Figura 5).




Fig. 4 – Variação a curto prazo na frequência de acidentes num determinado local. Fonte: AASHTO, 2010.




Fig. 5 – Comparação da diferença entre a eficácia percebida e real eficácia de um tratamento, devido ao enviesamento to FRM. Fonte: AASHTO, 2010.

Apesar de muitas medidas tradicionais para melhoria da SR não levarem esse fenómeno em consideração, muito progresso já foi feito mundialmente, especialmente na UE desde os anos 2000 para tornar as estradas mais seguras. É, no entanto, perceptível a estagnação da redução das mortes que tem ocorrido na última década, isto porque as medidas tradicionais de redução da sinistralidade tornam-se cada vez menos efetivas à medida em que os acidentes se tornam mais escassos nestes países. Face a isso, e com a ambição da “Visão Zero” de atingir zero mortos e feridos graves na UE até 2050, abordagens mais sistemáticas, como o Sistema Seguro (SS), devem ser adotadas em conjunto com as abordagens tradicionais já utilizadas (OECD/ITF, 2008; Comissão Europeia, 2020; ETSC, 2021).

Dentre os princípios do SS para reduzir a sinistralidade rodoviária, esta abordagem sugere a melhoria proativa das estradas e veículos, sem que seja necessário esperar que acidentes ocorram num local para que medidas de redução da sinistralidade sejam tomadas ali, tornando assim todo o sistema seguro (ANSR, 2020; Wegman, F., 2021).

Fundamentados em métodos científicos, os modelos de previsão de acidentes (MPA) permitem relacionar os acidentes com fatores que contribuem para sua ocorrência, revelando-se uma ferramenta útil de apoio à decisão que permitem a adoção de medidas enquadradas na abordagem do SS, uma vez que auxiliam na melhoria proativa da Segurança Rodoviária (SR).

Para tal, é importante perceber que, embora um único acidente seja imprevisível, dado que são eventos aleatórios e raros, uma parcela da sua variação é oriunda de fatores que podem ser controlados (Fridstrøm L. *et al.*, 1995).

Segundo Cardoso, J. e Gomes, S. (2002), a ocorrência dos acidentes é influenciada pelos elementos do sistema de tráfego, nomeadamente, aqueles relacionados aos utentes, ao veículo e ao ambiente rodoviário. As ocorrências podem ser contributo de cada elemento individualmente, ou também da interação entre os mesmos (Figura 6), e.g., quando a envolvente rodoviária induz o condutor a comportamentos erróneos.




Fig. 6 – Influência dos elementos do sistema de tráfego nos acidentes rodoviários. Fonte: Cardoso, J.; Gomes, S. (2002).

Desta forma, com base em uma sólida base de dados de acidentes e dos vários fatores causais, é possível efetuar uma análise robusta dos acidentes para perceber o que de facto contribui para sua ocorrência num determinado local. Se tal for conseguido, poderá ser muito relevante para o estudo e seleção de medidas preventivas mais efetivas de redução da sinistralidade.

Das possíveis aplicações de um MPA em prol da SR, destacam-se (Hauer, E., 2004; Caliendo, C. *et al.*, 2006; AASHTO, 2010; Saito, M. *et al.*, 2011; Srinivasan, R. *et al.*, 2013; Torre, F. *et al.*, 2016):

- Identificação preditiva de secções para tratamento por *ranking* dos locais perigosos (*network screening*);
- Prever o potencial impacto de mudanças em determinadas características, normalmente viárias, em termos de redução/ aumento dos acidentes;
- Avaliação do “antes” e “depois” da implementação medidas de tratamento (*safety effectiveness evaluation*).

Somado a isso, Ambros J. *et al.* (2017; 2018) ainda mencionam a análise económica custo-benefício dos projetos como outra possível aplicação dos MPAs. Independente da aplicação adotada, a utilização de MPAs traz inúmeros benefícios para a melhoria da SR, podendo ser uma ferramenta importante no objetivo de zero mortes e feridos na UE até 2050.

Apesar do esforço inicial necessário para a sua construção, os modelos preditivos para a rede rodoviária são instrumentos que permitem uma alocação de verbas mais eficiente, dado que as potencialidades de previsão permitem que as medidas de segurança passem a ser selecionadas de forma mais orientada.

Sendo assim, o desafio inicial passa pela construção de modelos preditivos fundamentados cientificamente; de utilização intuitiva; facilmente atualizáveis e versáteis para que sirvam de base para a tomada de decisão (Peltola, H. *et al.*, 2013) e o presente trabalho visa considerar esses aspetos na elaboração e aplicação dos modelos para a autoestrada A25.

2.2. A MODELAÇÃO NA SEGURANÇA RODOVIÁRIA

Os modelos de previsão de acidentes consistem na modelagem estatística, ou por meio de técnicas como o *Machine Learning* para estimar o nível de segurança rodoviária, por meio de dados como o número de acidentes, vítimas, feridos e mortos que ocorrem num determinado local (um segmento de estrada ou intersecção) durante um período de tempo, com base em fatores causais.

A modelação consiste em representar a realidade de forma simplificada e bem ajustada, e nos modelos estatísticos, o elemento central é a equação geral do modelo, que relaciona o número esperado de acidentes, num determinado local e período de tempo, com os fatores de risco, dada por (Hauer E., 2004):

$$Y = f(X_1, X_2, X_3, \dots, X_n \quad \beta_1, \beta_2, \beta_3, \dots, \beta_n) \quad (1)$$

Sendo a função $f()$ a que relaciona o número esperado de acidentes por unidade de tempo, Y (variável dependente), numa entidade com características $X_1, \dots, X_n$ (variáveis independentes) com parâmetros $\beta_1, \dots, \beta_n$. Os parâmetros da regressão são estimados, e seu valor dependerá da função utilizada e das variáveis independentes escolhidas.

Para determinar a forma funcional $f()$ que relaciona a variável dependente Y , com as explicativas, é necessário fazer pressuposição acerca da distribuição dos dados de Y . Já na modelação com uso de técnicas de *Machine Learning* (ML), como o uso de *Artificial Neural Networks* (ANN) que é cada vez mais comum nos MPAs encontrados na literatura, não é necessário fazer a definição da relação a priori, pois o próprio método identifica uma relação entre os dados, evitando possíveis erros na definição da forma funcional (que poderiam levar a inferências erróneas), sendo que tais técnicas têm gerado bons resultados de previsão (Silva, P., 2019).

Por outro lado, segundo Lord D. e Mannering, F. (2010) e Rashidi M. *et al.* (2022), além de o uso da ML requerer maior quantidade de dados, algumas destas técnicas funcionam como “black-boxes” pois não fornecem parâmetros interpretáveis, impedindo o entendimento da contribuição de cada variável explicativa nos resultados. Por essa razão, com base nos objetivos que se pretende obter com o presente trabalho, foi utilizada a modelagem estatística que, quando feita corretamente, também é capaz de fornecer bons resultados (Mannering, F. e Bhat, C., 2014).

A elaboração de um modelo estatístico de previsão de acidentes será abordada mais aprofundadamente no Capítulo 2.3, porém, em suma, o seu desenvolvimento passa pelos seguintes passos, que resultam no cálculo do valor esperado dos acidentes $E[Y]$ expresso por μ (Papacostas, C. e Prevedouros, P., 2009; Ferreira S., 2010):

- 1) Seleção das variáveis independentes;
- 2) Levantamento dos dados para construção da base de dados a ser utilizada no modelo;
- 3) Definição da forma matemática $f()$ que relaciona as variáveis independentes à variável de resposta;
- 4) Definição da distribuição probabilística que rege a componente aleatória Y , resultante dum conjunto de observações y ;
- 5) Estimação dos parâmetros da função $f()$;
- 6) Validação do modelo: testes para determinar sua capacidade de explicar a realidade.

2.3. MODELOS DE FREQUÊNCIA DE ACIDENTES

No que toca à variável de resposta, os modelos preditivos podem ser distinguidos como modelo de frequência de acidentes e modelos de acidentes por severidade, sendo do primeiro tipo os modelos elaborados neste estudo. Pretende-se fazer uma análise quantitativa do nível de segurança, por meio da frequência dos acidentes como variável de resposta, expressa pelo número esperado de acidentes por unidade de tempo.

Grande parte dos estudos com modelos de frequência de acidentes relacionam a frequência de acidentes, com os fatores viários-ambientais. Uma importante publicação acerca da previsão de frequência de acidentes é o Highway Safety Manual (HSM) publicado pela AASHTO (2010), na qual a metodologia baseia-se em fórmulas matemáticas criadas por modelos estatísticos de regressão com distribuição probabilística Binomial Negativa. Nestas fórmulas, os acidentes em intersecções e autoestradas são dados em função do TMDA (Tráfego Médio Diário Anual) e características geométricas da via.

Essa metodologia pode ser prontamente transferível para outros locais, sendo para isso necessário utilizar um fator de calibração para considerar as diferenças nas características das vias e comportamento dos condutores, dentre outros elementos, entre a rede viária utilizada para desenvolver os modelos do HSM e a rede na qual o modelo preditivo será aplicado (AASHTO, 2010; Yannis, G. *et al.*, 2016).

A previsão de acidentes pela metodologia do HSM é uma ferramenta relativamente simples para a previsão de acidentes, e as funções foram desenvolvidas com base em redes dos Estados Unidos. Embora alguns estudos relatem que sua transferência para outras redes traga bons resultados, a metodologia pode não ter a mesma eficiência quando as características de um local diferem muito das características para o qual o modelo foi criado.

Isto é recorrente nos MPAs transferidos para redes fora dos Estados Unidos, como nos países da União Europeia (Eenink R. *et al.*, 2005; Ambros, J. *et al.*, 2017). A título de exemplo, as normas de design, e características operacionais nas autoestradas na América do Norte são bastante distintas daquelas na EU, o que pode gerar estes resultados menos satisfatórios (Gomes, S., 2012).

Além dos fatores mencionados anteriormente, por vezes é relevante estudar o efeito de outras variáveis no nível de segurança viária, e, portanto, pode ser mais vantajoso criar modelos preditivos específicos para a rede que se quer estudar, desde que existam dados suficientes para fazê-lo, pois estes devem gerar melhores resultados.

Este estudo aborda a criação de MPAs locais para uma autoestrada e para tal serão utilizados Modelos Lineares Generalizados (MLG), que têm sido amplamente adotados na modelação para a segurança viária da frequência de acidentes (Ferreira, S., 2010; Kronprasert, N. *et al.*, 2021).

2.3.1. FORMA FUNCIONAL DO MODELO

Em comparação com os modelos lineares clássicos, nos MLG a função de ligação entre a componente aleatória de Y , e a componente sistemática ($x_1, x_2, \dots, x_p$) pode ser diferente da linear, e a distribuição pode ser qualquer uma da família exponencial. Um MLG é especificado em três etapas (McCullagh, P. e Nelder, J. A., 1989; Gelman, A. *et al.*, 2021):

- A componente aleatória, especificando a distribuição da variável de resposta, cujo valor esperado é dado pelo valor médio $E[Y] = \mu$. Esta distribuição pode depender de um parâmetro de dispersão.
- A componente sistemática, que produz o preditor linear η :

$$\eta_i = \sum_{j=1}^p \beta_j x_{ij} \quad (2)$$

Sendo a componente sistemática do modelo η_i , com i observações e j variáveis independentes, representada em função das x_{ji} variáveis independentes, e os β_j parâmetros a serem estimados.

- A função de ligação $g()$ que relaciona a componente aleatória (dada por μ) e a componente sistemática:

$$\mu = g^{-1}(\eta) = g^{-1}(X\beta) \quad (3)$$

De facto, a distribuição Normal não é adequada para a descrever a componente aleatória dos acidentes. Na realidade, os dados dos acidentes ajustam-se bem às distribuições da família exponencial por serem dados de contagem (números inteiros e não-negativos), o que torna os MLG adequados para modelar os acidentes (Lord, D. e Mannering, F., 2010; Zhang, Y. *et al.*, 2012).

Desta forma, para garantir que os valores dos acidentes sejam números positivos, o número esperado de acidentes é expresso na forma exponencial, resultando, por fim, na forma funcional mais comumente utilizada nestes modelos (Eenink R., *et al.* 2005; Zhang, Y., *et al.*, 2012):

$$E[y] = \alpha Q^\beta e^{\sum_j^p \beta_j x_{ij}} \quad (4)$$

Que na forma logarítmica fica:

$$\ln \mu = \ln \alpha + \beta \ln Q + \sum_j^p \beta_j x_{ij} \quad (5)$$

Sendo $E[y]$ o valor esperado da frequência dos acidentes em um determinado segmento, expresso em função do tráfego Q e um conjunto de fatores de risco x_j , com $j=1, \dots, p$, e α e β os parâmetros a estimar.

Ao linearizar pela função logarítmica, te modelos de regressão log-linear, um tipo específico de MLG. Um dos modelos mais utilizados de regressão log-linear para a modelagem dos acidentes são a regressão de Poisson e Binomial Negativa (Tegge, R. *et al.*, 2010).

2.3.1.1. Modelo de Regressão de Poisson

Antes de efetuar a estimativa dos parâmetros do modelo, é necessário especificar a distribuição probabilística da componente aleatória (Ferreira, S., 2010). Como visto anteriormente, os modelos de regressão que utilizam a distribuição de Poisson adequam-se bem para obtenção do número esperado de acidentes em função as variáveis explicativas.

Na regressão de Poisson, a probabilidade de a entidade viária (segmento, intersecção) i ter y_i acidentes num determinado período de tempo é dada por:

$$Prob(Y = y_i | x_i) = \frac{e^{-\lambda_i} \lambda_i^{y_i}}{y_i!} \quad (i = 1, \dots, n) \quad (6)$$

Onde λ_i é o parâmetro de Poisson para a entidade de viária i (Greene, W., 2008; Lord, D. e Mannering, F., 2010).

A estimação é feita pela especificação de λ_i , sendo a função de ligação entre as variáveis explicativas e λ_i dada por:

$$\lambda_i = e^{(\beta_j x_{ij})} \quad (7)$$

Ou, equivalentemente:

$$\ln(\lambda_i) = \beta_j x_{ij} \quad (8)$$

Na regressão de Poisson, o parâmetro λ_i equivale ao número esperado de eventos por período de tempo, sendo, portanto, o número esperado de acidentes (eventos) dado por:

$$E[y_i] = \lambda_i = e^{(\beta_j x_{ij})} \quad (9)$$

Sendo β_j os parâmetros a serem estimados para as j variáveis explicativas x_{ij} .

A regressão de Poisson assume que $Var[y_i] = \lambda_i$, ou seja, a variância é igual à média. Entretanto, tal condição nem sempre é satisfeita, o que pode afetar a precisão dos parâmetros β_j , resultando em maiores discrepâncias entre os valores estimados dos acidentes e os valores realmente observados (Lord, D. e Park, P., 2008). Por essa razão, costumam ser usadas alternativas à regressão tradicional de Poisson, como a regressão Binomial Negativa.

2.3.1.2. Modelo de Regressão Binomial Negativo

O modelo de regressão Binomial Negativo (BN) é uma extensão do modelo de Poisson, que costuma ser utilizada para evitar enviesamento nos resultados da estimação dos parâmetros quando há sobredispersão nos dados dos acidentes, pois não condiciona que haja constância da probabilidade de ocorrências, isto é, que a variância seja igual à média durante todo o período estudado.

A sobredispersão dos dados ocorre quando a variância da variável excede a média, e é muito comum que este fenómeno ocorra nos dados dos acidentes (Lord, D. e Mannering, F., 2010). Por essa razão, a regressão BN costuma ser preferível para modelar os acidentes (Geedipally S. *et al.*, 2008).

Para diminuir o efeito da sobredispersão, além da componente aleatória assumir a distribuição de Poisson, na distribuição BN é considerado um erro que segue a distribuição Gama, com média 1,0 e variância α (Lopes, A. e Cardoso, J., 2007).

Portanto, a probabilidade de a entidade viária (segmento, intersecção) i ter y_i acidentes num determinado período de tempo é dada por:

$$Pr o b(Y = y_i | x_i) = \frac{\Gamma\left(\frac{1}{\alpha} + y_i\right)}{\Gamma\left(\frac{1}{\alpha}\right)} \left[\frac{\frac{1}{\alpha}}{\left(\frac{1}{\alpha} + \lambda_i\right)} \right]^{\frac{1}{\alpha}} \left[\frac{\lambda_i}{\left(\frac{1}{\alpha} + \lambda_i\right)} \right]^{y_i} \quad (10)$$

Sendo $\Gamma(\cdot)$ a função Gama, e α o parâmetro de sobredispersão. A função de ligação dá-se por:

$$\lambda_i = e^{(\beta_j x_{ij} + \varepsilon_i)} \quad (11)$$

Onde $e^{(\varepsilon_i)}$ é o erro com distribuição Gama (Roque, C. e Cardoso, J., 2014). O valor esperado de acidentes é então expresso por:

$$E[y_i] = \lambda_i = e^{(\beta_j x_{ij} + \varepsilon_i)} \quad (12)$$

E variância da distribuição toma um valor distinto da média:

$$Var[y_i] = E[y_i]\{1 + \alpha E[y_i]\} \quad (13)$$

Segundo Lord, D. e Park, P. (2008), altos valores do parâmetro de dispersão α indicam que há grande sobredispersão. Por outro lado, quando α se aproxima de 0, a variância aproxima-se da média, então a distribuição BN reverte para a distribuição de Poisson.

2.3.2. ESTIMATIVA DOS PARÂMETROS DA FUNÇÃO

A estimativa do modelo consiste em determinar os valores dos parâmetros da regressão, obtidos de com base no conhecimento experimental, por meio das observações dos acidentes. Nos modelos preditivos de acidentes, os parâmetros β são comumente estimados por métodos de máxima verosimilhança, ou por métodos Bayesianos (Lord, D. e Mannering, F., 2010).

Os métodos de estimação Bayesiana mostram-se úteis em modelos com forma funcional complexa, permitindo obter intervalos de credibilidade da estimação dos parâmetros. Neste tipo de análise, para se estimar as propriedades da distribuição dos dados que não podem ser obtidas analiticamente, o método de Monte Carlo via Cadeias de Markov (MCMC) pode ser utilizado para a realização de análises exaustivas até a convergência para uma distribuição a posteriori (Lopes, S.; Cardoso, J., 2009).

Entretanto, para as regressões não lineares como a regressão de Poisson e BN, costumam existir formas fechadas de funções de verosimilhança (Lord e Mannering, 2010), o que simplifica o processo de estimação dos parâmetros. Na estimação pelo método da Máxima Verosimilhança, dentre os possíveis valores dos parâmetros populacionais, são selecionados os que mais aproximem as ocorrências de uma amostra à realidade (Guimarães, R. e Cabral, J., 1997).

$$L(\beta) = Prob(Y_1 = y_1, \dots, Y_n = y_n | \beta_1, \dots, \beta_R) \quad (14)$$

Os valores dos parâmetros β que maximizam a função da verosimilhança $L(\beta)$, ou $\ln L(\beta)$ são obtidos pelas estimativas de máxima verosimilhança resolvendo a equação diferencial: (Greene, W., 2008):

$$\frac{\partial L}{\partial \beta_i} = 0 \quad (i = 1, \dots, R) \quad (15)$$

A função de verosimilhança para a regressão de Poisson e para a BN são respetivamente (Greene, W., 2008):

$$\ln L = \sum_{i=1}^n [-\lambda_i + y_i x_i \beta - \ln y_i !] \quad (16)$$

Já na regressão BN, por considerar a sobredispersão, as estimativas são quase-verosimilhanças (Milton, J. e Mannering, F., 1998):

$$L = \prod_i \frac{\Gamma\left(\frac{1}{\alpha} + y_i\right)}{\Gamma\left(\frac{1}{\alpha}\right) y_i!} \left[\frac{\frac{1}{\alpha}}{\left(\frac{1}{\alpha} + \lambda_i\right)} \right]^{\frac{1}{\alpha}} \left[\frac{\lambda_i}{\left(\frac{1}{\alpha} + \lambda_i\right)} \right]^{y_i} \quad (17)$$

Por fim, com a estimação dos parâmetros, pode ser mais conveniente avaliar que as variáveis explicativas exercem sobre a variável de resposta, pela estimação da mudança em valor percentual do número esperado da frequência dos acidentes μ_i devido a uma mudança de 1% na variável independente, mantendo-se todas as outras constantes (Ferreira, 2010). Para variáveis independentes contínuas a elasticidade é dada por (Washington, S., et al., 2003):

$$E_{x_{ij}}^{\mu_i} = \frac{\partial \mu_i}{\partial x_{ij}} \times \frac{x_{ij}}{\mu_i} = \beta_j x_{ij} \quad (18)$$

Quando este valor é igual a 1, há uma elasticidade perfeita de x , havendo uma mudança de igual percentagem na variável de resposta.

Sendo E a elasticidade, x_{ij} o valor da j -ésima variável explicativa para observação i , e β_j o parâmetro estimado para a j -ésima variável independente, e μ_i o valor esperado da frequência de acidentes para a observação i .

As variáveis independentes também podem ser *dummies* ao invés de contínuas, tomando valores de “0 ou 1”. Nestes casos, os parâmetros da regressão são utilizados para calcular uma elasticidade aproximada, por meio da Pseudo-Elasticidade, que fornece a mudança incremental na frequência dos acidentes causada por mudanças nas variáveis explicativas (Washington, S. et al., 2003):

$$E_{x_{ij}}^{\mu_i} = \frac{e^{\beta_j} - 1}{e^{\beta_j}} \quad (19)$$

2.3.3. VALIDAÇÃO DOS MODELOS

É essencial garantir a validade dos modelos de forma a assegurar que os resultados obtidos são adequados à realidade, e assim, serem utilizados na prática. Medidas de desempenho e análises gráficas permitem perceber a qualidade de ajuste do modelo aos dados (validade replicativa), e o poder

explicativo das variáveis independentes sobre o fenómeno (variável dependente). Nô último caso, o teste estatístico da Razão de Verossimilhança indica se os modelos com as variáveis independentes representam uma melhora, em relação ao modelo apenas sem nenhuma variável explicativa.

Sendo assim, com o intuito de avaliar tanto a qualidade do ajuste, quanto comparar resultados entre modelos distintos, as medidas de qualidade podem guiar a seleção de um modelo em oposição a outro, tais como (UCLA, 2021):

- χ^2 de Pearson - compara os valores previstos pelo modelo com os valores reais, pela fórmula:

$$\sum_{i=1}^n \frac{(y_i - \hat{y}_i)^2}{\hat{y}_i} \quad (20)$$

Onde $\hat{y}_i$ é o valor previsto de y_i .

- Logaritmo da verossimilhança do modelo final: máximo valor da verossimilhança;
- Critério de informação Akaike (AIC):

$$AIC = -2\log L + 2p \quad (21)$$

Em que p é o número de parâmetros no modelo, e L é a função de verossimilhança do modelo final. Esta métrica penaliza modelos com muitos parâmetros, recomendando a escolha de modelos com menor AIC;

- Critério de informação Bayesiano (BIC):

$$BIC = \frac{-2 \ln L + p \ln(n)}{n} \quad (22)$$

É avaliado de forma equivalente ao AIC, preferindo-se modelos com menor BIC.

Recomenda-se que mais de uma métrica de desempenho seja utilizada para avaliar o ajuste dos modelos (Lord D. e Park P., 2008).

A análise gráfica dos resíduos acumulados pelo método CURE (Cumulative Residuals), também permite examinar a qualidade de ajuste do modelo. Este método, proposto por Hauer, E. e Bamfo, J. (1997), é uma alternativa ao gráfico de resíduos e permite perceber melhor se a forma funcional do modelo se adequa bem aos dados.

No método CURE, os resíduos (diferença entre os valores observados e previstos da variável dependente) são apresentados em valores acumulados, em função de valores crescentes da uma variável independente. Neste gráfico, percebe-se um bom ajuste quando os valores dos resíduos acumulados oscilam em torno do eixo horizontal tendendo a estabilizar no valor nulo, e não ultrapassam as curvas limites aceitáveis ($\pm 2\sigma$), em que σ é determinado pela equação:

$$\sigma = \hat{\sigma}(n) \sqrt{1 - \frac{\hat{\sigma}^2(n)}{\hat{\sigma}^2(N)}} \quad (23)$$

Onde N é o número total de resíduos, n um número inteiro entre 1 e N , e $\hat{\sigma}^2(n)$ a soma dos resíduos quadrados de 1 a n . (Hauer, E., 2004).

Quando há picos acima que ultrapassam a banda delimitadora superior (definida por $+2\sigma$), a contagem de acidentes é maior que a previsão do modelo (subestimação), enquanto para picos abaixo da banda inferior (-2σ), o modelo está a sobrestimar o número de acidentes.

A avaliação da performance preditiva dos modelos é uma etapa complementar que permite avaliar se o modelo é capaz de prever o fenómeno em estudo com uma boa aproximação da realidade. Uma forma de fazê-la consiste em estimar mais uma vez os parâmetros do modelo, porém para uma base de dados com apenas parte período de tempo utilizado no modelo original (dados para calibração). Em seguida, o novo modelo é utilizado para prever os acidentes dos restantes anos (dados para previsão), e a validação é feita com análises gráficas (Papacostas, C. e Prevedouros, P., 2009; Ferreira, S., 2010), podendo-se utilizar novamente o gráfico dos resíduos acumulados para a análise.

2.3.4. VARIÁVEIS INDEPENDENTES

Como visto no início do Capítulo 2.3, os modelos preditivos normalmente concentram-se nos fatores viários-ambientais para determinar o nível de segurança nas vias. Apesar de não explicarem a causa dos acidentes por completo, visto que sua ocorrência geralmente decorre de uma combinação de fatores humanos, veiculares e viários-ambientais, a utilização destes modelos preditivos como ferramenta de melhoria da segurança rodoviária tem grande potencial para a obtenção de bons resultados na redução da sinistralidade. Isto porque, a partir da análise do efeito das variáveis no nível de segurança rodoviária, as medidas de redução da sinistralidade, como mudanças à nível da infraestrutura, sinalização e controlo de tráfego tornam-se mais fundamentadas e, portanto, com potencial para serem mais efetivas.

Para além do comportamento dos condutores ser mais difícil de prever e modelar, as estradas também devem dar margem ao erro humano (Saito, M. *et al.*, 2011), estando essa orientação alinhada com a abordagem do Sistema Seguro. Este pensamento não exclui a responsabilidade dos condutores, mas permite que as estradas sejam projetadas para que, quando ocorra um acidente, suas consequências sejam menos graves.

Desta forma, justifica-se o estudo voltado apenas para os fatores que estão mais facilmente ao alcance da ação das entidades gestoras. Normalmente estes fatores são relativos às condições geométricas e operacionais da via (e.g. o traçado em planta, perfil longitudinal e volume de tráfego), e condições ambientais (Eenink, R., *et al.*, 2005; Ambros, J., *et al.*, 2018; Silva, P., 2019).

Segundo Fridstrøm, L. (2015), dentre esses fatores, a exposição ao risco de acidentes são provavelmente as variáveis explicativas mais importantes nos modelos preditivos. Geralmente a exposição é expressa nos modelos em termos do volume de tráfego e, quando feito para segmentos de extensões variáveis da via, a extensão também deve ser levada em conta.

Por fim, a seleção das variáveis a incluir no modelo acaba por ser condicionada pela disponibilidade dos dados. De acordo com E. Eenink, R., *et al.* (2005) a escolha das variáveis a utilizar no modelo deve levar em conta variáveis já estudadas anteriormente e que demonstraram considerável influência nos acidentes.

De seguida, é necessário identificar as variáveis que tenham alta correlação (duas a duas) para manter no modelo apenas que faça mais sentido para o que se quer estudar, evitando assim erros de especificação. Com as variáveis restantes é feita eliminação daquelas não têm significância estatística, mantendo no modelo apenas as que apresentem um bom nível de confiança (normalmente maior ou igual a 90%). Entretanto, de acordo com Ferreira, S., (2010), as variáveis que apresentam relação de causa-efeito pouco significantes com os acidentes (níveis de confiança inferiores a 90%) podem ser mantidas no modelo desde que não afetem os níveis de confiança das outras variáveis.

Apesar do ajuste teórico ideal se dar quando o número de variáveis explicativas é igual ao número de observações (McCullagh, P. e Nelder, J. A., 1989), isto além de impraticável, também impede que se obtenha um modelo simples, que possa ser facilmente compreendido e atualizado. Por essa razão deve-se manter um conjunto parcimonioso de variáveis, isto é, construir o modelo que explique bem o fenómeno dos acidentes com um número reduzido de variáveis explicativas, incluindo apenas aquelas que exercem efeito considerável sobre a variável de resposta.

2.4. SEGMENTAÇÃO DAS VIAS

A segmentação constitui uma etapa fundamental para a construção da base de dados dos modelos de frequência de acidentes para autoestradas. Segundo Cafiso, S. *et al.* (2018), este processo consiste em agregar os dados em entidades viárias homogêneas, e a forma como é feita influencia o desenvolvimento e aplicação do modelo preditivo.

Existem diversas formas de se realizar este processo, que normalmente consistem em:

- Divisão da via em segmentos de extensões variáveis (e.g. Caliendo, C., *et al.*, 2007; Koorey, G. 2009; Zhang, Y. *et al.*, 2012; Souza, S., 2021; Ribeiro, J., 2021): neste tipo de segmentação, os segmentos apresentam homogeneidade em algumas características, normalmente relativas a geometria das vias e do volume de tráfego, por toda sua extensão. Desta forma, todas as vezes que uma destas características muda, é criado um novo segmento;
- Divisão da via em segmentos de extensões fixas (e.g. Chang, L. e Chen, W., 2005; Geyer, J. *et al.*, 2008; Costa, J., *et al.*, 2015; Silva, P., 2019): normalmente os comprimentos são fixados na casa das centenas. Nestes casos, as características geométricas dominantes de cada segmento podem ser as utilizadas para o modelo, ou são atribuídos pesos para uniformizar as variáveis num segmento.

Ambos processos têm vantagens e desvantagens (Silva, P. *et al.*, 2019), e não existe um consenso acerca de qual a melhor forma de realizar a segmentação. A definição da forma a realizá-la acaba por depender do propósito do modelo, e também da base de dados relativa à infraestrutura e operação viária disponível. Mesmo quando é feita a segmentação por características em comum, com comprimentos variáveis, as características a utilizar diferem muito de estudo para estudo.

2.4.1. EXTENSÃO DOS SEGMENTOS

A extensão dos segmentos resultante do critério selecionado exerce grande influência no resultado do MPA. Contudo, independente do critério escolhido, também não há consenso acerca de quais são as máximas e mínimas extensões ideais (Silva, P. *et al.*, 2019).

Por um lado, segmentos muito curtos podem gerar erros de inferência estatística devido a:

- Atribuição errónea dos acidentes aos seus devidos segmentos, resultado da localização imprecisa dos acidentes no momento em que são reportados (Hauer, E., 2004);
- Natureza rara e aleatória dos acidentes, resultando numa maior quantidade de segmentos pequenos que contém zero observações para o período selecionado (Ambros, J. *et al.*, 2018).

Já os segmentos mais extensos diminuem a incerteza devido a falhas na georreferenciação dos acidentes (localização imprecisa), e agregam maior número de registos de acidentes, diminuindo o problema das zero observações. Por outro lado, segmentos muito extensos podem perder sua aplicabilidade ao forçar a homogeneização das variáveis contínuas em categorias (Cafiso, S. *et al.*, 2018; Ambros, J. *et al.*, 2018).

Em termos de aplicabilidade dos modelos preditivos, Ambros, J. *et al.* (2018) referem que a criação de segmentos com maiores extensões tem sido a mais comum para a hierarquização do nível de segurança das vias, enquanto segmentos mais curtos são mais usados para estimar o benefício de tratamentos localizados.

No caso da segmentação com características constantes (comprimento variável), essa extensão vai depender das características definidas para a homogeneização, e quanto mais características utilizadas para definir um segmento, menor vai ser a extensão do mesmo.

2.4.2. SEGMENTAÇÃO COM EXTENSÕES VARIÁVEIS

Apesar das suas vantagens, como a maior facilidade de criação que segmentos de extensões variáveis, os segmentos de extensão fixa podem ter geometria muito variável, sendo necessário a atribuição de pesos a estes atributos para homogeneizar cada segmento. Por essa razão, a interpretação do efeito das variáveis nos acidentes pode tornar-se menos intuitiva (Koorey, G., 2009; Green, E., 2018; Ribeiro, J., 2021).

Neste trabalho foi utilizada a segmentação por extensões variáveis, sendo, portanto, necessário incluir no modelo a extensão do segmento como variável explicativa dado o seu caráter de “exposição” ao risco de acidentes. Para este caso, é necessário fazer uma escolha cautelosa das características selecionadas para tornar um segmento homogêneo, pois isto irá ditar quais as extensões mínimas e máximas resultantes da segmentação. A título de exemplo, é possível que para as mesmas características selecionadas, a segmentação numa autoestrada em zona urbana gere extensões mais curtas que numa autoestrada rural, pois a primeira costuma possuir maior variação na geometria.

O HSM (AASHTO, 2010) fornece indicações das características a utilizar para a criação dos segmentos homogêneos com extensões variáveis. Muitos autores abordam também metodologias análogas, mas sem seguir à risca o HSM, tal como Caliendo, C. *et al.* (2007) que utilizaram a curvatura horizontal e a inclinação longitudinal como critério de homogeneização; ou Koorey G., (2009) que considerou apenas o traçado em planta das vias com base nos padrões de tangentes e curvas; enquanto Souza, S. (2021) e Ribeiro, J. (2021) consideraram algumas características do perfil transversal para além do traçado em planta.

3

CASO DE ESTUDO

3.1. METODOLOGIA

Este trabalho consistiu na elaboração de modelos de previsão de acidentes rodoviários para a autoestrada Portuguesa A25 (BLA), a fim de utilizá-los como apoio à decisão na SR. Além de permitirem a identificação e avaliação do efeito que os fatores de risco viários exercem na ocorrência dos acidentes, os MPAs podem ser aplicados de diversas formas para definir locais e critérios para tratamento. Por fim, os modelos constituem uma ferramenta proativa e eficiente, permitindo que sejam tomadas decisões antes mesmo de se registarem acidentes nos locais.

A abordagem efetuada foi quantitativa, com um modelo de previsão de frequência de acidentes totais e outro de previsão de frequência de acidentes com vítimas. O objeto de estudo foi a autoestrada da Ascendi A25, para os troços em plena via (sublanços), ou seja, localizados entre os nós. Diversos dados tiveram que ser recolhidos e tratados para construção da base de dados, que teve como etapa essencial a segmentação da autoestrada de forma a agregar os dados por segmentos (unidade de observação), não tendo sido as características individuais (como condutores e veículos) consideradas para estudo. Os dados históricos dos acidentes utilizados foram dos anos 2015 a 2021.

Para chegar à relação entre as variáveis explicativas, denominadas como a componente sistemática, e os acidentes (componente aleatória), foram utilizados modelos lineares generalizados, e a distribuição da variável dependente (acidentes totais ou com vítimas) selecionada foi a que melhor se ajustou aos dados para cada caso, dentre a distribuição de Poisson e a Binomial Negativa.

A estimação dos parâmetros foi feita pelo Método da Máxima Verossimilhança, no *software* IBM SPSS versão 28, e algumas medidas de desempenho e o gráfico dos resíduos acumulados foram analisados para avaliar a qualidade de ajuste dos modelos. De seguida, quantificou-se o efeito individual de cada variável na probabilidade de acidentes, por meio do cálculo da elasticidade e pseudo-elasticidade.

Além de avaliar a qualidade de ajuste dos modelos, foi feita a validação para verificar a capacidade de os modelos preverem os acidentes, pela criação de novos modelos com dados apenas de 2015 a 2019 (dados para calibração), e fazendo-se o gráfico dos resíduos acumulados de 2020 e 2021 (dados para previsão).

Finalmente, fez-se uma aplicação prática dos modelos que revelaram boa capacidade de previsão. A aplicação teve como base a previsão os acidentes para o ano de 2023, supondo mudança numa das variáveis explicativas (procura de tráfego). De forma que os modelos sejam efetivamente usados na Ascendi, auxiliando nas estratégias para redução da sinistralidade, fizeram-se também algumas recomendações de utilização e atualização das ferramentas. A estrutura da metodologia está ilustrada na Figura 7.




Fig. 7 – Estrutura do trabalho.

3.2. DEFINIÇÃO DA ÁREA DE ESTUDO

3.2.1. SEGURANÇA RODOVIÁRIA NA REDE ASCENDI E EXPERIÊNCIA COM MPA'S

A Ascendi é uma empresa de gestão de ativos rodoviários, com prestação de serviços de cobrança de portagens e de operação e manutenção de infraestruturas, atualmente responsável por 626 km de autoestradas concessionadas pelo Estado Português – Figura 8.




Fig. 8 – Rede Ascendi. Fonte: Anuário de Segurança Rodoviária, 2021.

Tendo em vista a redução da sinistralidade rodoviária, a empresa desenvolveu e está a implementar o seu Plano de Ação de Segurança Rodoviária (PASR 2020-2023), no qual define metas e medidas de prevenção, mitigação e compreensão dos acidentes, com o objetivo de atingir uma redução anual de vítimas em 5%.

Das medidas de prevenção selecionadas em sintonia com o Visão Zero e a abordagem do Sistema Seguro, estão a ser desenvolvidos modelos preditivos de acidentes rodoviários em autoestradas geridas pela empresa, como já foi feito por Souza, S. (2021) e Ribeiro, J. (2021) – Quadro 1.

Quadro 1 – Modelos preditivos criados para as autoestradas da Ascendi.

	Souza, S. (2021)	Ribeiro, J. (2021)	Presente Estudo
Autoestrada	A29 – Concessão Costa de Prata	A44 – Concessão Costa de Prata	A25 – Beiras Litoral e Alta
Segmentação	Características homogéneas (comprimento variável)	Características homogéneas (comprimento variável)	Características homogéneas (comprimento variável)
Variável Dependente	Acidentes Totais e Acidentes com Vítimas	Acidentes Totais e Acidentes com Vítimas	Acidentes Totais e Acidentes com Vítimas
Forma funcional do modelo	MLG	MLG	MLG
Regressão mais ajustada aos dados dos acidentes	Poisson	Poisson	Capítulos 4.1.1. e 4.2.1.
Período estudado	2015-2019	2015-2020	2015-2021
Fatores mais relevantes encontrados: Modelo de Acidentes Totais	TMDA; Comprimento; nº e Largura das Vias	TMDA; Comprimento; Limite de velocidade e Raio de curvatura	Capítulo 4.1.3.
Fatores mais relevantes encontrados: Modelo de Acidentes com Vítimas	TMDA; Comprimento; Raio de Curvatura e Largura da Berma	TMDA; Comprimento e Raio de curvatura	Capítulo 4.2.3.
Output	Identificação e interpretação do efeito de fatores de risco; Identificação preditiva de ZAAs.	Identificação e interpretação do efeito de fatores de risco; Teste da capacidade de previsão do modelo em contextos disruptivos.	Identificação e interpretação do efeito de fatores de risco; Previsão de acidentes para um cenário futuro.

Ambas autoras criaram modelos para a frequência de acidentes, e Souza, S. (2021) aplicou o modelo de acidentes totais para a identificação das ZAAs pelo ranking dos segmentos críticos pelo indicador de desempenho “excesso de acidentes”, dado pela diferença entre o número de acidentes estimado pelo modelo e observado no mesmo ano. Os segmentos que mereceram atenção foram identificados como aqueles que tiveram mais acidentes do que o esperado (indicando mau desempenho do local face às suas características), e não necessariamente os segmentos que registaram mais acidentes (abordagem tradicional das ZAAs).

Já Ribeiro, J. (2021) testou a adequação do modelo na A44 e A29 para os anos atípicos, que foi o caso do ano de 2020, no qual foram tomadas medidas de redução de circulação em Portugal devido à pandemia SARS Cov-2. Os acidentes neste ano foram consideravelmente menores devido à redução do tráfego, ainda assim, os modelos analisados pela autora revelaram-se estáveis, sendo considerados adequados para utilização em anos atípicos.

O presente trabalho visa expandir os estudos para a autoestrada A25, e leva em consideração as dificuldades detetadas pelas autoras na elaboração dos modelos e suas recomendações, tendo em vista

aprimorar a criação dos modelos para que possam ser utilizados na empresa como ferramenta de gestão da sinistralidade rodoviária.

Especial atenção foi dada ao processo de segmentação, que nos trabalhos anteriores resultaram em muitos segmentos curtos com zero acidentes. Para evitar que isto ocorresse, esta etapa consistiu em utilizar menos características para definir um segmento homogêneo, seguida de uma análise minuciosa dos segmentos curtos resultantes, para então definir os critérios para a “correção” destes segmentos.

3.2.2. DADOS DA ASCENDI

A Ascendi possui uma extensa base de dados da sua rede, sendo grande parte das informações georreferenciadas numa plataforma Sistema de Informação Geográfica (SIG) própria da empresa (Figura 9), a qual auxilia na localização, recolha e interpretação dos dados de forma sistemática. Destes dados, os mais relevantes para o presente trabalho são os dados dos acidentes, do volume de tráfego, dados das velocidades e os dados relativos à infraestrutura.




Fig. 9 – Acidentes do ano corrente ilustrados na plataforma SIG da Ascendi. Fonte: Ascendi (2022).

A Figura 10 mostra os dados dos acidentes (totais e com vítimas) e o volume de tráfego, expresso em TMDA [veículos/dia], para toda rede da Ascendi durante o período de estudo deste trabalho, que compreende os anos de 2015 a 2021. Já na Figura 11, vê-se a distribuição do número de vítimas, por tipologia, para o período de estudo em toda rede Ascendi.




Fig. 10 – Comparação entre o número de acidentes e o TMDA na rede Ascendi (2015-2021).




Fig. 11 – Número de feridos ligeiros, feridos graves e mortos na rede Ascendi (2015-2021).

Percebe-se uma certa relação entre o TMDA, uma variável que mede a exposição ao risco de acidentes, e os registos de acidentes totais, sendo esta relação ainda mais evidente para os acidentes com vítimas. Entretanto, ressalta-se uma tendência menos clara entre o TMDA e os acidentes nos anos de pandemia do Covid-19, nomeadamente 2020 e 2021. Durante a pandemia foram implementadas medidas de restrição da circulação em muitos países, inclusive Portugal, de forma a conter o vírus, diminuindo bruscamente o volume de tráfego nas cidades e entre cidades. Nestes anos, apesar da súbita redução do

TMDA, a redução no número de acidentes, não seguiu a tendência esperada com base no padrão dos anos anteriores.

Existem diversos fatores que podem ter alterado a relação entre os acidentes e o TMDA nesse período. Isto se dá porque a pandemia pode ter gerado diferentes níveis de conflito nas autoestradas e maiores velocidades praticadas, devido a menores volumes de tráfego; mudanças na escolha modal de transporte (Ferreira, S. *et al.*, 2022) e consequentemente mudaram os condutores que circulam na autoestrada; estilo de vida (e.g. teletrabalho e preferência por circular em períodos de tráfego menos carregado, alterando os padrões do tráfego); ou até mesmo devido a alterações no comportamento dos condutores.

A título de exemplo, Muley, D. *et al.* (2020) mencionam a possível conduta mais perigosa, resultante da menor percepção de risco por conta de haver menos veículos a circular. Para além da condução mais agressiva, com não cumprimento dos limites de velocidade, frenagens mais bruscas e desrespeito aos sinais, os estudos de Dong, X. *et al.* (2022) e Lopetrone, E. e Biondi, F. (2022) apontam para o aumento da condução desatenta durante a pandemia, o que também contribui para maior probabilidade de acidentes.

Estas mudanças, principalmente nas velocidades de circulação, exercem grande influência na probabilidade de ocorrerem acidentes, explicando a diferente relação entre o número de acidentes e volume de tráfego observada durante a pandemia. O estudo feito por Katrakazas, C. *et al.* (2021) revelou que em 2020 na Grécia, apesar de grande diminuição dos acidentes totais devido às restrições de circulação, os acidentes com feridos graves e mortos reduziram em menor taxa. Já no estudo de Islam, M. *et al.* (2022), observou-se que, apenas os acidentes mortais reduziram em menor taxa na Flórida, enquanto os acidentes totais e com feridos graves parecem ter acompanhado a redução do tráfego.

3.2.3. AUTOESTRADA A25

A A25 compreende as concessões da Costa de Prata (CP) e Beiras Litoral e Alta (BLA), tendo o trecho que compõe a CP cerca de 22.9 km. Este trecho tem início no nó do Porto de Aveiro e fim no limite da concessão, no nó com a A1, na região da Albergaria e trata-se de uma zona mais suburbana da A25.

Já o trecho da A25 que integra a BLA, possui características distintas. Este trecho tem um total de 172,3 km, com nó de início na Albergaria, com fim em Vilar Formoso, próximo à fronteira com a Espanha, cruzando, com exceção do trecho entre Viseu e Mangualde, zonas mais rurais em Portugal, de Oeste a Este (Figura 12). A BLA integra a Rede Transeuropeia de Transportes, sendo uma importante rede a nível europeu, e tem destaque no transporte nacional e internacional de cargas.



Fig. 12 – Mapa da autoestrada A25 (BLA). Fonte: Ascendi (2021).

Embora o presente trabalho inicialmente abrangesse ambas as concessões da A25, à medida que os modelos foram sendo desenvolvidos ficou evidente a necessidade de tratar esses trechos de forma distinta, devido às suas características bastante diferentes, de forma a obter modelos mais fiéis à realidade.

A diferença de característica ocorre em diversos casos, como na relação entre TMDA e os acidentes, percentagem de veículos pesados, geometria das vias ou nas velocidades permitidas. Sendo assim, de forma a otimizar os modelos em um período de tempo limitado, optou-se por trabalhar somente com o trecho da A25 pertencente à BLA.

Nas Figuras 13 e 14, é possível observar as distintas tendências nos anos da pandemia. Enquanto em 2020 na BLA houve uma redução semelhante à observada em toda a rede Ascendi no mesmo ano (Figura 10), tanto para o tráfego como para os acidentes, na A25 CP os acidentes totais e com vítimas aumentaram, apesar da redução do TMDA.

Já em 2021, em que ocorreu uma ligeira retoma dos volumes de tráfego pré-pandemia após o abrandamento de algumas medidas de restrição, o número de acidentes totais na BLA se manteve bem próximo ao de 2020, enquanto o número de vítimas agravou-se. Por outro lado, no mesmo ano na A25 CP, os acidentes totais retomaram mais rapidamente que o TMDA, enquanto o número de acidentes com vítimas diminuiu.

De forma a complementar a análise, a distribuição do número de vítimas nas duas concessões, por tipologia, está ilustrada nas figuras 15 e 16. Vê-se mais uma vez as diferenças entre a A25 que integra a BLA e a que integra a CP.




Fig. 13 – Comparação entre o número de acidentes e o TMDA na A25 Costa de Prata (2015-2021).




Fig. 14 – Comparação entre o número de acidentes e o TMDA na A25 Beiras Litoral e Alta (2015-2021).




Fig. 15 – Número de feridos ligeiros, feridos graves e mortos na A25 CP (2015-2021).




Fig. 16 – Número de feridos ligeiros, feridos graves e mortos na BLA (2015-2021).

É possível ainda verificar a relevância da extensão percorrida como uma variável de exposição ao risco de acidentes, pois apesar da BLA ter maior registo de acidentes que o trecho que compõe a CP, a primeira é bastante extensa, e a relação de acidentes com vítimas por quilómetro é maior para o trecho da CP, possivelmente pela última ser uma autoestrada urbana, e por isso, por exemplo, ter mais conflitos com outras vias, aumentando o risco de acidentes (Figura 17).




Fig. 17 – Comparação da Sinistralidade/Extensão da A25 CP vs BLA

3.3. RECOLHA, TRATAMENTO DOS DADOS E SELEÇÃO DAS VARIÁVEIS

3.3.1. RECOLHA E TRATAMENTO DOS DADOS

Inicialmente, foi necessário recolher uma série de dados com informações dos registos dos acidentes, geometria e secção transversal da autoestrada, volume de tráfego, limites de velocidade e equipamentos de controlo. Em seguida, fez-se a filtragem e tratamento dos dados de forma utilizar aqueles que fossem mais relevantes para o estudo.

A existência de uma base de dados rica e atualizada disponibilizada pela empresa foi fundamental para a criação dos modelos. Por outro lado, a análise aprofundada dos dados da A25 possibilitou a deteção de pequenos erros e omissões de informações, que devido à magnitude da autoestrada estudada não afetariam o desempenho do modelo, mas que foram corrigidos quando possível.

Dados da Infraestrutura

Os dados da infraestrutura estão associados à sua localização, que pode ser num nó ou num arco (sublanço), que correspondem aos troços em plena via localizados entre os nós. Os sublanços são os objetos de estudo do presente trabalho e seus respetivos PK (pontos quilométricos) de início e fim são mostrados no Quadro 2. O trecho da A25 que integra a BLA contém 29 sublanços.

Quadro 2 – Sublanços da A25 (BLA) e seus respectivos PK de início e fim.

Sublanço	PK Inicial	PK Final	Extensão [km]
Limite de Concessão – Z.I. de Albergaria	24590	25054	0,5
Z.I. de Albergaria – IC2	25054	29034	4,0
IC2 (EN1) – Carvoeiro	29034	32102	3,1
Carvoeiro – Talhadas	32102	43235	11,1
Talhadas – Reigoso	43235	50066	6,8
Reigoso – Cambarinho	50066	56112	6,0
Cambarinho – Vouzela Poente	56112	61417	5,3
Vouzela Poente – Vouzela Nascente	61417	63407	2,0
Vouzela Nascente – Ventosa	63407	69286	5,9
Ventosa – Boa Aldeia Poente	69286	74439	5,2
Boa Aldeia Poente – Boa Aldeia Nascente	74439	75397	1,0
Boa Aldeia Nascente – Fail (A24/A25)	75397	84731	9,3
Fail (A24/A25) – EN231	84731	88426	3,7
EN231 – EN2	88426	94574	6,1
EN2 – Caçador	94574	96563	2,0
Caçador – Fagilde	96563	101595	5,0
Fagilde – Mangualde	101595	105334	3,7
Mangualde – Chãs de Tavares	105334	117621	12,3
Chãs de Tavares – Fornos de Algodres	117621	125852	8,2
Fornos de Algodres – Celorico	125852	137923	12,1
Celorico – EN17	137923	139055	1,1
EN17 – Ratoeira Poente	139055	144034	5,0
Ratoeira Poente – Ratoeira Nascente	144034	146332	2,3
Ratoeira Nascente – IP2/A25	146332	146964	0,6
IP2/A25 – Guarda	146964	161133	14,2
Guarda – Pinhel	161133	163070	1,9
Pinhel – Pínzio	163070	177283	14,2
Pínzio – Alto de Leomil	177283	184697	7,4
Alto de Leomil – Vilar Formoso	184697	196872	12,2
Total BLA			172,3

Os dados recolhidos para a construção da base de dados do modelo, relativos à infraestrutura, estão identificados pelo PK de início e fim, o sublanço e sentido ao qual o trecho pertence. São eles:

- Características do traçado em planta: reta, clotoide ou curva circular e seus respectivos raios;
- Características geométricas: número, tipo e largura das vias; largura das bermas exteriores e interiores; tipo e largura do separador central;
- Características operacionais: velocidade limite permitida; existência/ não existência de controlo eletrónico de velocidade;
- Tipo de pavimento: flexível ou rígido;
- Características de perfil longitudinal: inclinação; raio da curva circular (côncava/convexa);
- Características de trecho: plena via; garrafão de entrada/saída; área de portagem;
- Características de zona: aterro/escavação/misto; viaduto/obra de arte.

Como será abordado no Capítulo 3.4, as características do traçado em planta e geométricas foram fundamentais para criação dos segmentos e por essa razão, alguns trechos foram eliminados do estudo, devido à inexistência de informação do seu traçado em planta. Aliás, os sublanços do nó de Angeja (A25/A29) ao trecho inicial do IC2 (EN1) – Carvoeiro; Fail (A24/A25) ao EN2 foram por esse motivo eliminados da análise, resultando em 157,7 km para estudo.

Dados do Tráfego

Foi essencial recolher o TMDA, que constitui uma variável fundamental para expressar a exposição ao risco de acidentes. O TMDA está disponibilizado por sublanço, e foi recolhido para os anos de 2015 a 2021, fazendo-se a distinção de sentidos e categoria de veículos, sendo por fim calculada a percentagem de pesados. Os valores mencionados para a BLA estão representados no Anexo A.

Na Figura 18 o TMDA na A25 para o período de estudos está expresso pelo total de veículos (ligeiros e pesados), e somente por pesados. Ressalta-se novamente a diferença entre o trecho da CP e o da BLA, pois apesar de o volume de tráfego ser consideravelmente maior na A25 pertencente à Costa de Prata, a BLA tem maior procura relativa de veículos pesados, o que era de esperar, dada a importância deste trecho no transporte de cargas.




Fig. 18 – Comparação entre o TMDA na A25 CP e BLA.

Dados dos Acidentes

É necessário ter dados suficientes para fazer uma análise robusta e contornar o problema da variação aleatória dos acidentes se estudados num curto prazo de tempo. Para este estudo, em que a variável de resposta para um modelo foram os acidentes totais e para o outro foram os acidentes com vítimas (mortais, feridos graves e feridos ligeiros), foram considerados os dados georreferenciados destes acidentes dos anos 2015 a 2021, ocorridos em plena via.

No Quadro 3, estão sumarizados os acidentes na A25 (BLA) recolhidos para o modelo. No total, a série histórica possui 1014 registos em plena via para o MPA de Acidentes Totais, e 340 registos para o MPA de Acidentes com Vítimas. Por fim, após eliminação dos trechos sem informação do traçado em planta, restaram 931 registos de acidentes (totais), e 311 registos de acidentes com vítimas a serem utilizados nos modelos.

Quadro 3 – Dados dos acidentes em plena via de 2015 a 2021, por Ano e Sentido, na BLA.

Ano	2015		2016		2017		2018		2019		2020		2021		Total 2015 a 2021
Sentido	C	D	C	D	C	D	C	D	C	D	C	D	C	D	-
Acidentes Totais	55	77	94	85	58	67	74	78	87	95	54	67	61	62	1014
Acidentes com Vítimas	19	30	32	25	19	31	21	23	24	35	13	24	21	23	340

3.3.2. SELEÇÃO DAS VARIÁVEIS

Esta fase consistiu em definir as variáveis que se pretende estudar, com base na literatura e na disponibilidade de dados.

Variáveis dependentes

As variáveis de resposta para um dos modelos consistem na frequência de acidentes totais, que corresponde à soma dos acidentes apenas com danos materiais e acidentes com vítimas (mortes, feridos graves e feridos ligeiros), e para o outro modelo o fenómeno estudado é a frequência de acidentes com vítimas.

Variáveis Independentes

Sendo a unidade de observação deste estudo o segmento rodoviário, importa estudar apenas os dados agrupados por cada segmento, não sendo as características individuais dos acidentes (relativas ao condutor, veículo e condições ambientais) consideradas (Souza, S. 2021).

Portanto, as variáveis independentes utilizadas no modelo dizem respeito às características em planta, de secção transversal e operacionais da via. A sua seleção baseou-se nos fatores relevantes encontrados na revisão bibliográfica, e passa pela procura de um equilíbrio entre a qualidade do ajuste e a simplicidade do modelo para, por um lado, representar a realidade o melhor possível, e por outro, eliminar variáveis irrelevantes que reduziriam a precisão do modelo (Li, J. e Yu, W., 2021).

Sendo assim, as variáveis independentes selecionadas foram as apresentadas a seguir. Os valores por elas tomados estão ilustrados mais pormenorizadamente no Capítulo 3.5.

- a) Características em planta:
 - Existência de traçado em curva circular ($R > 900\text{m}$) / reta/ clotóide; ou curva circular ($R \leq 900\text{m}$), e seu respetivo raio [m];
 - Comprimento do segmento [m].

A extensão do segmento representa a exposição ao risco dos acidentes, sendo esperada uma relação linear com os acidentes, dado que, quanto maior a distância percorrida, maior a probabilidade de ocorrer um acidente.

Já para o alinhamento, apenas interessou distinguir quando existia uma curva circular de raio $R \leq 900\text{m}$ ou não, visto que curvas de raio reduzido, em conjunto com maiores velocidades de circulação na via estão associadas a maior ocorrência de acidentes, quer pelo efeito da força centrífuga, quer pela diminuição da visibilidade dos condutores.

- b) Características da secção transversal:
 - Número de vias principais (esquerda, direita e centrais);
 - Largura da berma exterior [m];
 - Largura do separador central [m];
 - Existência de outras vias (aceleração, desaceleração e lentos).

Os elementos do perfil transversal também contribuem para uma maior ou menor ocorrência de acidentes e na sua gravidade. Maiores larguras das bermas permitem, por exemplo, que os condutores recuperem o controlo do veículo em situações de despiste antes que possam colidir com algum veículo, ou objeto da lateral da via. Já maiores larguras do separador central diminuem o risco de colisão frontal entre veículos que circulam em sentidos opostos, bem como a influência do tráfego do sentido oposto na sua condução.

Vias mais largas podem afetar a visibilidade transversal do condutor, conforto e percepção de risco (Souza, S., 2021). A existência de outras vias, como vias de aceleração podem gerar maior conflito entre os veículos, e maior número de vias alteram a capacidade e as manobras na via, bem como percepção na condução.

- c) Características operacionais:
 - Tráfego médio diário anual (TMDA) [veíc. /dia];
 - Percentagem de pesados;
 - Velocidade limite permitida [km/h];
 - Existência de equipamento de controlo de velocidade.

O volume de tráfego, expresso em TMDA para representar a exposição ao risco de acidentes é fundamental para o modelo (Khodadadi, A. *et al.*, 2022). Segundo (Zhang, Y. *et al.*, 2012), muitos autores consideram uma relação linear entre esta variável e a probabilidade de ocorrer um acidente. Por outro lado, muitos estudos também têm evidenciado que os acidentes podem variar mais rapidamente ou lentamente com aumentos no volume de tráfego, ou até mesmo de forma não monótona (Roque, C.

e Cardoso, J., 2014). Isto pode se dar devido a diversos fatores locais, como a capacidade da via e variações no volume ao longo do tempo (Elvik, R. *et al.*, 2009).

A velocidade também está relacionada ao risco de ocorrência de um acidente, pois quanto maior, maior a distância percorrida após a travagem e também se torna mais difícil o controlo do veículo. Maiores velocidades também estão relacionadas à gravidade do acidente, pois há maior energia cinética transferida no impacto (Wegman, F. e Aarts, L., 2006).

3.4. SEGMENTAÇÃO DA AUTOESTRADA A25

Uma etapa fundamental para a elaboração dos modelos consistiu na segmentação da autoestrada e posterior atribuição das variáveis a serem utilizadas no modelo aos seus respectivos segmentos. A base de dados é então construída de forma que a unidade de observação do modelo seja o segmento.

Como mencionado no Capítulo 2.4., na autoestrada A25 foi utilizada a segmentação por comprimentos variáveis. Este critério de segmentação consistiu em criar um novo segmento cada vez que alguma característica da plena via mudasse. Várias podem ser as características utilizadas para definir um segmento homogêneo, normalmente relativas à geometria, perfil transversal, e características de operação das vias.

É um processo trabalhoso de ser feito manualmente, não existindo uma forma padronizada e automatizada de efetuá-lo. De forma a elucidar a transição da teoria à prática, buscou-se elaborar em detalhe o processo de segmentação feito neste trabalho.

3.4.1. FASE 1 – DIVISÃO EM SEGMENTOS HOMOGÊNEOS COM BASE NA GEOMETRIA DA AUTOESTRADA

A segmentação por características homogêneas (extensões variáveis) consiste em criar trechos homogêneos para determinadas características da via. Além da A25 ter sido dividida por sublanços, foi criado um novo segmento sempre que alguma das seguintes características mudava:

- a) Características do traçado em planta
 - Existência/não existência de Curva Circular de raio ≤ 900 m.

- b) Características do perfil transversal
 - Largura da via (esquerda ou direita);
 - Largura da berma (interior ou exterior);
 - Largura do separador central [m];
 - Número de vias principais (direita, esquerda e central);
 - Existência/não existência de outras vias, que não entram para o “Número de vias”: via de lentos, aceleração e desaceleração.

Algumas características como a largura da berma interior, apesar de consideradas inicialmente, não foram utilizadas por serem constantes na autoestrada estudada.

A distinção do traçado em planta deu-se apenas pela existência da curva circular para evitar que segmentos muito curtos fossem criados caso se fizesse a distinção entre reta, clotóide e curva circular. Sendo assim, buscou-se evitar o problema de muitos segmentos com zero contagens de acidentes e também localização imprecisa dos acidentes, e consequentemente, um modelo enviesado.

A curva circular com raio ≤ 900 m foi seleccionada pela maior tendência de ocorrerem acidentes em raios mais fechados, e o critério de escolha do valor do raio foi baseado no raio mínimo absoluto para o limite de comodidade numa estrada de vias múltiplas, para uma velocidade base de 120 km/h.

De forma a automatizar este processo e evitar considerável tempo despendido numa segmentação manual, esta etapa teve apoio do departamento de informática da empresa, que construiu um algoritmo na linguagem de programação C#, para criar um novo segmento sempre que alguma das características da previamente definidas mudassem.

Para tal, foi necessário cruzar os dados de mais de uma folha de cálculo, nomeadamente os dados relativos às características em planta, com os dados das características do perfil transversal, e por fim obteve-se a informação no ficheiro de cálculo *Excel*, onde cada linha representa um segmento, associado ao sublanço, sentido e PK de início e fim. O resultado obtido no ficheiro de cálculo para um trecho do sublanço da A25 está exposto no Quadro 4.

Tal processo resultou em 1001 segmentos, para os 157 quilómetros da A25 (BLA) estudados, sendo deste total, 497 no sentido Crescente e 455 no sentido Decrescente. A Figura 19 ilustra o trecho equivalente aos segmentos representados no Quadro 4.

Quadro 4 – Amostra da folha de cálculo resultante da 1ª fase da segmentação.

Localização	Sentido	PK Inicial	PK Final	Curva Circular R $\leq$ 900 m	Largura [m]									
					Separador Central	Via Esquerda	Via Central Esq.	Via Central	Via Central Dir.	Via Direita	Via Lentos	Via Aceleração	Via Desaceleração	Berma Exterior
Mangualde – Chãs de Tavares	C	110530	110709	700	4	3,75	N/A	N/A	N/A	3,75	3,5	N/A	N/A	1,5
Mangualde – Chãs de Tavares	C	110709	110782	N/A	4	3,75	N/A	N/A	N/A	3,75	3,5	N/A	N/A	1,5
Mangualde – Chãs de Tavares	C	110782	111138	N/A	4	3,75	N/A	N/A	N/A	3,75	N/A	N/A	N/A	3,5




Fig. 19 – Representação dos três segmentos do Quadro 4.

Em seguida, o ficheiro foi organizado de forma que facilitasse a 2ª fase e posterior inserção da base de dados no *software* para modelação.

Finalmente, estes seguimentos foram “replicados” para cada ano de estudo, resultando em 7007 segmentos, para os 7 anos que serão analisados os acidentes, sendo 3528 no sentido Crescente e 3479 no sentido Decrescente.

Tratamento dos Segmentos

Apesar da cautelosa seleção das características que definem um segmento homogêneo, para que não fossem criados muitos segmentos, e consequentemente mais segmentos curtos, foi inevitável o seu surgimento de alguns, mesmo na BLA que é mais constante na sua geometria que o trecho da A25 constituinte da CP. Em uma breve análise, notou-se que o traçado em planta e a existência/ não existência de vias a mais foram provavelmente as características que mais geraram novos segmentos.

Tendo em vista minimizar o problema dos zero acidentes nestes segmentos, os segmentos com extensões curtas foram analisados, à procura de um critério de “correção” que por um lado, reduzisse o problema dos zero acidentes, e por outro, não eliminasse muitos registos. Por fim, decidiu-se eliminar os segmentos com extensão ≤ 50 m, retirando da análise apenas 10 registos de acidentes totais, e 1 registo de acidentes com vítimas.

Após a correção, restaram 6377 segmentos, para a A25, sendo deste total, 3192 no sentido Crescente e 3185 no sentido Decrescente.

3.4.2. FASE 2 – AFETAÇÃO DAS VARIÁVEIS DO MODELO AOS SEUS RESPECTIVOS SEGMENTOS

A segunda fase da segmentação consistiu na afetação aos 6377 segmentos dos dados operacionais, nomeadamente:

- TMDA;
- % de Pesados;
- Velocidade limite permitida;
- Existência de equipamentos de controlo de velocidade (radares).

Os dados do TMDA e da percentagem de pesados inseridos em cada segmento são os referentes ao sublanço e sentido (crescente ou decrescente) e ano ao qual aquele segmento pertence. Já as velocidades máximas legalmente permitidas foram distinguidas por sentido e trecho do sublanço, entretanto, devido à poucas mudanças nas velocidades permitidas na A25 desde o ano de 2015, e à ausência de dados para os anos anteriores, esta variável tomou valores iguais para todos os anos da análise.

Finalmente, para que possa ser criado o modelo, são atribuídos a cada um dos segmentos os acidentes que serão estudados no modelo, neste caso:

- Número de acidentes totais
- Número de acidentes com vítimas

Deste modo, foi ainda necessário identificar qual o segmento a que um acidente com determinado PK pertence. A atribuição dos dados operacionais e dos acidentes a seus respetivos sublanços foi feita em *Excel* com auxílio de funções. O Quadro 5 mostra a base de dados utilizada na modelagem de um dos sublanços da A25, após completa segmentação e tratamento dos dados.

Quadro 5 – Base de dados referente ao trecho do sublanço Mangualde – Chãs de Tavares, sentido crescente representado no Quadro 4.

PK Inicial	PK Final	Comprimento [m]	Raio Curva Circular [m]	Larg. Sep. Cent. [m]	Larg. Berma Exterior [m]	Nº Via	Larg. Vias [m]	Outras vias	Ano	Limite Velocidade [km/h]	TMDA [veic/dia]	% Pesados	Radar	Nº Acidentes Totais	Nº Acidentes com Vítimas
110 530	110 709	179	700	4	1,5	2	3,75	Lentos – 3,5 m	2017	120	4624	25%	0	0	0
110 709	110 782	73	N/A	4	1,5	2	3,75	Lentos – 3,5 m	2017	120	4624	25%	0	1	0
110 782	111 138	356	N/A	4	3,5	2	3,75	-	2017	120	4624	25%	0	0	0

3.6. MODELAÇÃO

Após a construção da base de dados, procedeu-se à modelação. As variáveis consideradas inicialmente para o modelo estão representadas do Quadro 6.

Quadro 6 – Variáveis inicialmente consideradas para o processo de modelação.

Variável Dependente	Descrição	Natureza
Acid_Tot	número de acidentes totais no segmento	Numérica
Acid_Vit	número de acidentes com vítimas no segmento	Numérica

Variáveis Independentes	Descrição	Natureza
LN_TMDA	Tráfego Médio Diário Annual	Numérica
LN_%_Pesados	% de tráfego de veículos pesados	Numérica
LN_Comprimento	extensão do segmento	Numérica
Num_Vias	número de vias	Categórica
Sent	sentido de viagem	Categórica
Radar	existência/ ou não de radar	Categórica
Raio	valor do raio das curvas circulares horizontais ≤ 900 m	Categórica
Outras	existência de vias adicionais	Categórica
Vel	velocidade limite	Categórica
Bext	largura da berma exterior	Categórica
Sep	largura do separador central	Categórica
Ano	ano	Categórica

A criação dos modelos consiste em relacionar a variável dependente com as variáveis independentes. As variáveis independentes podem ser contínuas ou categóricas, e para proceder com a modelação, as categóricas foram representadas em variáveis *dummy* que assumem o valor 1 ou 0, representando a existência ou não daquela característica, respetivamente.

Quando a variável categórica tem apenas duas categorias, uma assume o valor 0 e a outra 1. Já quando existem $n > 2$ categorias, a variável é representada por $n-1$ variáveis *dummy*.

Nos Quadros 7 e 8 está representada a descrição estatística das variáveis dependentes; de exposição (contínuas); e das categorias em que as variáveis categóricas foram desagregadas.

Quadro 7 – estatística descritiva das variáveis dependentes.

Variável de resposta	Mín.	Máx.	Média	Desvio padrão
Nº de Acidentes Totais	0	6	0,146	0,4521
Nº de Acidentes com Vítimas	0	4	0,049	0,2473

Quadro 8 – estatística descritiva das variáveis independentes.

Variáveis contínuas	Min	Max	Média	Desvio Padrão
Comprimento [m]	3.932	8.62	5.504	0.7575
TDMA [veic. /dia]	7.742	9.079	8.453	0.2869
%_Pesados	-2.137	-0.742	-1.508	0.2898

Variáveis categóricas		Categorias	Observações	%
Num_Vias	A	3 vias	21	0.3%
	B	4 vias	14	0.2%
	C	2 vias	6342	99.5%
Sent	0	Crescente	3192	50.1%
	1	Decrescente	3185	49.9%
Radar	0	Sem Radar	6335	99.3%
	1	Com Radar	42	0.7%
Raio	1	reta/clotoide ou curva circular com raio >900m	3689	57.8%
	2	curva circular com raio <=500m	1029	16.1%
	3	curva circular com 500m<raio<=900m	1659	26.0%
Outras_Vias	1	Aceleração/Desaceleração	868	13.6%
	2	Lentos	1470	23.1%
	3	Aceleração/Desaceleração & Lentos	224	3.5%
	4	não há	3815	59.8%
Veloc_lim	1	[60;90] km/h	35	0.5%
	2	100 km/h	2149	33.7%
	3	120 km/h	4193	65.8%
Bext	1	não há	7	0.1%
	2	1.5 m	1575	24.7%
	3	2 m	49	0.8%
	4	2.5 m	966	15.1%
	5	3 m	441	6.9%
	6	3.5 m	3339	52.4%
Sep	0	0,6 m	2471	38.7%
	1	>=4 m	3906	61.3%
Ano	1	2015	911	14.3%
	2	2016	911	14.3%
	3	2017	911	14.3%
	4	2018	911	14.3%
	5	2019	911	14.3%
	6	2020	911	14.3%
	7	2021	911	14.3%

Antes de se proceder à modelação efetivamente, e após a escolha das variáveis que se pretendia incluir no modelo, foi necessário analisar as variáveis independentes com alta correlação pela matriz de correlação. Para tal, foi construída a matriz de correlação de *Pearson* entre as variáveis independentes, disponível no Anexo B, para detetar, par-a-par, as variáveis com alta correlação, eliminando aquelas que são menos relevantes para o propósito do modelo (Ambros, J. *et al.*, 2018).

A matriz indica os coeficientes de correlação entre cada par de variáveis, que podem tomar valores entre -1 e 1 (-1 indica alta correlação negativa; 1 alta correlação positiva e 0 nenhuma correlação). Para definir quais pares de variáveis analisar, valores de correlação maiores que |0,8| foram classificados como muito correlacionados. Dentro deste critério, apenas as variáveis LN_TMDA e LN_%_Pesados são colineares, com um coeficiente de correlação igual a -0.821.

Sendo assim, foi necessário estabelecer qual das duas variáveis eliminar. Optou-se por manter o TMDA ao invés da percentagem de pesados, dada a unânime utilização da primeira variável nos modelos de previsão de acidentes já efetuados.

Após a revisão da literatura e construção da base de dados, chegou-se à conclusão de que os acidentes na BLA poderiam ser representados como função das variáveis apresentadas na equação:

$$E[Y]=f(TMDA; Compr; Num_Vias; Raio; Outras; BExt; Sep_Cent; Vel; Sent; Radar; Ano) \quad (24)$$

Em que $E[Y]$ é o valor esperado da frequência de acidentes, TMDA e COMPR as variáveis contínuas de exposição e as restantes variáveis são as categóricas.

Finalmente, deu-se início ao processo de modelação. Tanto para o modelo de acidentes totais como para o modelo de acidentes com vítimas, as seguintes etapas foram efetuadas com o auxílio do software *IBM SPSS*:

- 1) Modelação (MLG) com regressão de Poisson e outra com regressão BN para a variável de resposta;
- 2) Seleção do modelo de regressão que melhor se ajustou aos dados;
- 3) Eliminação das variáveis explicativas sem significância estatística. Nesta etapa foram mantidas apenas as variáveis com nível de confiança maiores ou iguais a 90% ou 95%;
- 4) Execução do modelo com as variáveis que restaram, obtendo os parâmetros da regressão.

3.7. VALIDAÇÃO DOS MODELOS

De forma a avaliar a qualidade do ajuste dos modelos aos dados (validade replicativa), analisou-se primeiramente algumas métricas de desempenho como o χ^2 de Pearson, AIC e BIC para simultaneamente escolher a distribuição (entre Poisson e BN) mais adequada para explicar a componente aleatória (acidentes), e por outro lado avaliar se o modelo escolhido é bem ajustado aos dados.

Em seguida, para o mesmo fim, fez-se a análise dos resíduos acumulados dos anos de 2015 a 2021 pelo método CURE para valores crescentes das variáveis TMDA e comprimento. Os resíduos foram calculados pela diferença entre o número observado de acidentes e o número previsto pelos modelos, para cada segmento. Se for verificado que os modelos têm bom poder explanatório da realidade, dá-se seguimento à interpretação do efeito das variáveis do modelo na probabilidade de ocorrerem acidentes.

Como mencionado no Capítulo 2.3.3., de forma a testar a capacidade de previsão dos modelos, fez-se mais uma vez as análises gráficas, porém para dados independentes, isto é, que não foram utilizados na calibração dos modelos. De forma a fazer isto, foi necessário estimar novamente os parâmetros dos modelos, mas com uma base de dados reduzida, apenas com dados de 2015 a 2019 (dados para calibração), para então prever os acidentes dos restantes 2 anos, isto é, 2020 e 2021 (dados independentes, para a previsão).

Antes de seguir para a validação preditiva, efetuou-se uma análise de semelhança entre os modelos com todos os dados (2015-2021) e o modelo com menos dados (2015-2019) – detalhada no Capítulo 4 -, de forma a aferir se é possível tirar conclusões sobre o primeiro modelo a partir do último. Caso afirmativo, faz-se finalmente o cálculo dos resíduos acumulados de 2020 e 2021 usando a previsão dos novos modelos (2015-2019). A análise destes últimos gráficos indica se os modelos podem ser usados na previsão.

4

RESULTADOS E ANÁLISES

Neste capítulo são apresentados em detalhe as etapas e resultados da construção e da validação dos modelos.

No total, foram elaborados dois modelos principais: um modelo de previsão de frequência de acidentes totais (MPA totais) e outro dos acidentes com vítimas (MPA com vítimas), com dados dos anos de 2015 a 2021. As variáveis independentes eliminadas dos modelos foram aquelas com níveis de confiança estatística inferiores a 95% para o MPA totais, e 90% para o MPA com vítimas.

Os modelos lineares generalizados foram criados no *software* IBM SPSS, capaz de estimar os parâmetros da regressão pelo método da máxima verossimilhança. A partir dos resultados, chegou-se às equações dos modelos utilizando a forma funcional expressa na Equação 4. Em seguida, fez-se o estudo do efeito que as variáveis explicativas exercem, individualmente, no aumento ou diminuição da probabilidade de ocorrerem acidentes.

Uma série de medidas de desempenho, como o χ^2 e o critério de informação de Akaike, foram avaliadas de forma a selecionar a regressão que melhor se ajustava aos dados (Poisson ou BN). Por fim, verificou-se que a distribuição de Poisson foi mais adequada aos acidentes totais, enquanto a distribuição BN obteve melhor ajuste para os acidentes com vítimas. Ainda de forma a avaliar a qualidade de ajuste dos modelos selecionados (validação replicativa), fez-se a análise gráfica dos resíduos acumulados dos acidentes pelo método CURE, para as variáveis de exposição.

De forma a avaliar a capacidade de previsão dos modelos (validação preditiva), foram criados mais um MPA totais, e outro MPA com vítimas, porém, com apenas 5 anos para calibração (2015-2019), e 2 anos (2020 e 2021) para a previsão. Estes modelos contêm as mesmas variáveis e distribuição dos modelos completos (7 anos), retirando-se apenas as variáveis que perderam significância estatística com os novos dados.

Numa etapa intermédia, fez-se uma análise comparativa entre os gráficos dos resíduos acumulados de 2015 a 2019 feitos com a previsão dos modelos com dados dos 7 anos e dos modelos com dados de apenas 5 anos. Para os gráficos que apresentaram padrões semelhantes, verificou-se que seria possível retirar conclusões do modelo completo (7 anos) a partir do modelo de 5 anos, seguindo-se para avaliação da capacidade de previsão dos modelos.

Finalmente, os acidentes totais e com vítimas foram então estimados utilizando a equação dos respetivos MPAs (2015-2019), para os anos não considerados na modelação, isto é, 2020 e 2021. Feito isso, procedeu-se à análise gráfica dos resíduos acumulados (CURE) para as variáveis de exposição, nos anos de 2020 e 2021. Em suma, verifica-se a capacidade de previsão do modelo completo a partir do modelo de 5 anos.

4.1. MODELO DE PREVISÃO DE FREQUÊNCIA DE ACIDENTES TOTAIS (2015-2021)

4.1.1. CONSTRUÇÃO DO MODELO

Para o modelo da frequência de acidentes totais para os 7 anos em estudo, foram mantidas apenas as variáveis que obtiveram níveis de confiança estatística iguais ou superiores a 95% na estimação dos parâmetros da regressão.

As medidas estatísticas representadas no Quadro 9 foram estudadas de forma a avaliar qual distribuição que melhor se ajustou aos dados. Tanto o modelo com distribuição de Poisson, como o modelo com distribuição BN, obtiveram valor-*p* nulo para o teste da razão de verossimilhança, revelando que o modelo completo, isto é, que incluía as variáveis independentes, traz uma melhoria significativa em relação ao modelo sem estas variáveis (apenas com o termo constante).

Em relação às medidas de qualidade de ajuste, a razão entre o valor do χ^2 e os graus de liberdade mostra valores próximos de 1,2, definido por (Gebregziabher, M. *et al.*, 2018) como um limite acima do qual a sobredispersão passa a ser problemática. Os valores de AIC e BIC e Logaritmo da Verossimilhança para a distribuição BN também revelam uma melhora, ainda que breve, do modelo BN em relação ao de Poisson.

Por outro lado, a razão entre a desviância e os graus de liberdade está abaixo de 1, indicando que não há sobredispersão. Somado a isso, além do parâmetro de sobredispersão estimado para a regressão BN ter valor muito próximo do 0, indicando que o modelo se aproxima da regressão de Poisson, na regressão BN surgiu o problema de singularidade na matriz Hessiana, o que pode causar estimação inadequada do modelo.

Quadro 9 – Medidas de desempenho do modelo de acidentes totais (7 anos).

Estatística de sumarização do modelo	Poisson		Binomial Negativo	
	Valor	Sig. (valor-p)	Valor	Sig. (valor-p)
Razão de Verossimilhança	676,831	0,000	487,568	0,000
Qualidade de ajuste do modelo	Valor	Valor/g.l.	Valor	Valor/g.l.
Desviância	3465,390 (6366 g.l.)	0,544	3345,937 (6365 g.l.)	0,526
Chi-quadrado de Pearson	7736,036 (6366 g.l.)	1,215	7593,823 (6365 g.l.)	1,193
AIC	5090,538	-	5071,823	-
BIC	5164,903	-	5152,948	-
Log. da verossimilhança (modelo final)	-2534,269	-	-2523,911	-
Parâmetro de Sobredispersão	-		0,113	

Por essas razões, optou-se por utilizar o modelo com regressão de Poisson para os acidentes totais. As variáveis eliminadas do modelo foram o número de vias (Num_Vias), sentido (Sent), a existência de equipamento de controlo de velocidade (Radar), largura da berma exterior (BExt), e Ano, dado não apresentarem significância estatística (valores-*p* foram maiores que 0,05). Os parâmetros estimados na

regressão de Poisson, incluindo apenas as variáveis com significância estatística, estão sumarizados no Quadro 10. O resultado completo obtido no *IBM SPSS* pode ser visto no Anexo C.1.

Variáveis Explicativas	Descrição	Parâmetro estimado	Desvio padrão	Sig. (valor-p)	Categoria de Referência
LN α	Constante	-21,830	1,211	0,000	-
LN_TMDA	TMDA (log. Natural)	1,709	0,128	0,000	-
LN_Compr	Comprimento do segmento (log. Natural)	0,900	0,045	0,000	-
Raio_C1	Curva Circular ($R > 900 $ m)/ Reta/ Clotóide	0,193	0,096	0,046	Curva Circular ($ 500 \text{ m} < R \leq 900 \text{ m}$)
Raio_C2	Curva Circular ($R \leq 500 $ m)	0,613	0,110	0,000	
Outras_C1	Via de Aceleração/Desaceleração	-0,653	0,160	0,000	Não existência de vias suplementares
Outras_C3	Via de Lentos & Via de Aceleração/Desaceleração	-0,860	0,307	0,005	
Sep_C0	Separador central de 0,6 m	0,220	0,068	0,001	Separadores centrais ≥ 4 m
Vel_C1	< 100 km/h	-2,097	1,002	0,036	120 km/h
Vel_C2	100 km/h	-0,150	0,074	0,043	

Utilizando a forma funcional exposta na Equação 4, os resultados originam a seguinte equação final do modelo de previsão de frequência de acidentes totais, em que $E[y]$ corresponde ao valor estimado de acidentes totais por ano, num determinado segmento:

$$E[y] = 3,31 \times 10^{-10} TMDA^{1,709} Compr^{0,900} \quad (25)$$

$$e^{0,193Raio_{C1} + 0,613Raio_{C2} - 0,653Outras_{C1} - 0,860Outras_{C3} + 0,220Sep_{C0} - 2,097Vel_{C1} - 0,150Vel_{C2}}$$

Sendo:

- *TMDA* – tráfego médio diário anual do segmento [veic./dia];
- *Compr* – o comprimento do segmento [m];
- *Raio* – categoria do raio do segmento (em que C1 equivale a curvas circulares de raio maior que 900 m, ou clotóide ou reta, e C2 equivale a curvas circulares de raio menor ou igual 500 m);
- *Outras* – categoria do tipo de via suplementar existente no segmento (em que C1 equivale a via de aceleração ou desaceleração, e C3 condiz a via de aceleração ou desaceleração e via de lentos, em simultâneo);
- *Sep* – categoria referente à largura do separador central no segmento (C0 equivale a separadores centrais com largura de 0,6 m);
- *Vel* – categoria referente ao limite de velocidade de circulação permitido no segmento (sendo C1 os limites de velocidade inferiores a 100 km/h, e C2 o limite de 100 km/h).

4.1.2. VALIDAÇÃO REPLICATIVA

De forma a avaliar graficamente a qualidade de ajuste do modelo, procedeu-se à análise dos resíduos acumulados pelo método CURE dos anos 2015 a 2021. Com esse intuito, foi elaborada uma folha de cálculo na qual utilizou-se a equação do modelo (Equação 25) para estimar o número de acidentes em cada segmento, por ano. Feito isso, calculou-se o resíduo, isto é, a diferença entre o número de acidentes observados, e o número de acidentes estimado pelo modelo, em cada segmento e ano.

Após a aplicação da equação, chegou-se aos valores dos resíduos acumulados, e dos limites inferior e superior $\pm 2\sigma$. O gráfico foi então feito para as variáveis contínuas TMDA (Figura 20) e comprimento (Figura 21), ordenadas em valores crescentes destas variáveis.




Fig. 20 – Gráfico dos resíduos acumulados dos acidentes totais (2015-2021) para a variável TMDA [veíc./dia] – modelo 7 anos.




Fig. 21 – Gráfico dos resíduos acumulados dos acidentes totais (2015-2021) para a variável comprimento [m] – modelo 7 anos.

Dos gráficos é possível concluir que as curvas para o TMDA e comprimento seguem um padrão próximo do desejado. Isto porque os resíduos oscilam em torno do eixo horizontal e terminam próximos do valor nulo, sem ultrapassar, quase na totalidade, os limites definidos por $\pm 2\sigma$.

A exceção ocorre apenas para maiores valores de TMDA (entre 7100 e 7500 veíc./dia), em que os resíduos acumulados ultrapassaram brevemente o limite $+2\sigma$. Para o comprimento, os resíduos acumulados também extrapolaram o limite superior em segmentos com extensões por volta de 600 m, e ligeiramente o limite inferior para gamas de segmento entre 60 e 70 metros e acima de 2500 m.

No entanto, o comportamento geral está de acordo com o proposto por Hauer, E. (1997), revelando, portanto, um bom desempenho do modelo para as duas variáveis.

4.1.3. INTERPRETAÇÃO DO EFEITO DAS VARIÁVEIS EXPLICATIVAS NOS ACIDENTES TOTAIS

Após a obtenção dos parâmetros estimados para as variáveis explicativas, importa perceber a influência que as variáveis do modelo (fatores de risco) têm na probabilidade de ocorrência dos acidentes totais (variável de resposta). Um valor positivo de elasticidade indica que a variável está relacionada com o aumento do risco de acidentes, enquanto um sinal negativo indica que a variável tem efeito na redução da probabilidade de acidentes, mantendo todas as outras variáveis constantes.

Para as variáveis contínuas, nomeadamente o TMDA e o Comprimento (variáveis de exposição), que foram inseridas na forma logarítmica, a elasticidade corresponde ao próprio parâmetro estimado no modelo (Equação 18). A análise do efeito destas variáveis no aumento ou diminuição da probabilidade de ocorrerem os acidentes está representada no Quadro 11. Neste caso, foi avaliado o efeito que o aumento de 10% no valor da variável representa no valor esperado da frequência dos acidentes totais.

Quadro 10 – Elasticidade das variáveis contínuas e aumento da probabilidade de acidentes para aumentos de 10% – MPA Acidentes Totais (2015-2021).

Variável	Parâmetro estimado	Elasticidade	Aumento/Diminuição da probabilidade de Acidentes
TMDA	1,709	1,709	17%
Comprimento	0,900	0,900	9%

Estima-se que os acidentes aumentem em 9% com um aumento em 10% da extensão do segmento, sendo uma relação quase-linear entre as variáveis, o que era expectável, visto que o comprimento representa um fator de exposição ao risco de acidentes, conforme já registado em vários estudos, como o de (Eenink, R. *et al.*, 2005).

Já um aumento do TMDA em 10% representa um aumento ainda maior no número esperado de acidentes (17%), que embora já não seja uma relação tão próxima da linear, está de acordo com os resultados obtidos em estudos como o de Ribeiro, J. (2021) e (Yu, R. e Abdel-Aty, M., 2013).

No caso das variáveis *dummy*, avaliou-se o efeito da existência /introdução da variável no valor esperado de acidentes totais, pela Equação 19. Os valores estão representados no Quadro 12.

Quadro 11 – Pseudo-Elasticidade das variáveis dummy – Acidentes Totais.

Variável (Código)	Descrição	Parâmetro estimado	Pseudo-Elasticidade	Aumento/Diminuição da probabilidade de Acidentes	Comparando com
Raio_C1	Curva Circular ($R > 900 $ m) / Reta / Clotóide	0,193	0,175	18%	Curva Circular ($ 500 \text{ m} < R \leq 900 \text{ m}$)
Raio_C2	Curva Circular ($R \leq 500 $ m)	0,613	0,458	46%	
Outras_C1	Via de Aceleração/ Desaceleração	-0,653	-0,921	-92%	Não existência de vias suplementares
Outras_C3	Via de Lentos & Via de Aceleração/ Desaceleração	-0,860	-1,364	-136%	
Sep_C0	Separador central de 0,6m	0,220	0,197	20%	Separadores centrais ≥ 4 m
Vel_C1	< 100 km/h	-2,097	-7,138	-714%	120 km/h
Vel_C2	100 km/h	-0,150	-0,162	-16%	

Verificou-se que a existência de separadores centrais de 0,6 m (Sep_C0) aumenta o risco de acidentes em 20%, em relação a separadores centrais mais largos (largura maior ou igual a 4 m). Esse resultado condiz com o verificado por (Elvik, R. *et al.*, 2009), ao observar que em autoestradas rurais, maiores larguras de separador central diminuem o risco de acidentes.

A variável Raio foi desagregada em três categorias, em que a categoria de referência foram segmentos em curva circular com raio entre 500 e 900 m. A categoria Raio_C1 representa os segmentos da autoestrada com geometria em planta menos sinuosa, nomeadamente, segmentos com reta, curva de transição (clotóide) ou curvas circulares com raios maiores que 900 m, enquanto a categoria Raio_C2 condiz aos segmentos em curva circular de raios menores ou iguais a 500 m.

Os valores de pseudo-elasticidade da variável revelam que, ao contrário do que podia se esperar, a categoria Raio_C1 aumenta o risco de acidentes em cerca de 18%, em relação a curvas circulares com $R \leq |900|$ m. Isto pode ser resultado da forma em que os condutores se adaptam à autoestrada, eventualmente optando, por exemplo, por velocidades mais elevadas devido à menor percepção de risco nos trechos menos curvos.

Já a pseudo-elasticidade da categoria Raio_C2 indica um aumento de 46% dos acidentes em relação à categoria de referência, revelando que curvas circulares mais fechadas ($\leq |500|$ m) apresentam maior risco em relação às curvas de raios maiores. Esse resultado está de acordo com o que seria intuitivo em termos de segurança, e corrobora com os estudos de (Glennon, J., 1987) e (Elvik, R. *et al.*, 2009).

A variável “Outras” representa a existência e o tipo de vias suplementares, neste caso, as vias que não fossem a via esquerda, direita e central. Com a desagregação em quatro categorias, sendo a categoria de referência os segmentos que não contém outras vias, a categoria Outras_C2 (via de lentos) não obteve significância estatística, tendo sido excluída da análise.

No caso da presença de segmentos da categoria Outras_C1 (existência de via de aceleração e/ou desaceleração) revela uma diminuição de 92% dos acidentes, em comparação com a não existência de vias a mais. A existência de vias de aceleração/desaceleração e vias de lentos, em simultâneo

(Outras_C3), representa uma diminuição ainda maior do número esperado de acidentes, em relação ao cenário em que não existem vias suplementares. Tais resultados vão contra o esperado, que seria o aumento no número de acidentes com a existência de mais pontos de conflito com as vias extras. Isto poderá ser uma variável *proxy* para diferentes fatores, relativos, por exemplo, à conduta humana, como maior cautela devido à maior percepção de risco em locais com muitos pontos de conflito.

Poderá também advir do facto que, como as vias de aceleração/desaceleração geralmente têm extensões reduzidas quando comparadas com os outros segmentos, pode ser que o acidente ocorrido numa via de aceleração/desaceleração tenha sido identificado como localizado no segmento posterior ou anterior.

De acordo com o esperado, a variável velocidade (Vel) revelou que para menores velocidades legalmente permitidas, maior a redução do risco de acidentes. Designadamente, estima-se que para velocidades permitidas menores que 100 km/h (Vel_C1), os acidentes diminuíam em 714%, e velocidade de 100 km/h (Vel_C2) diminua em 16% os acidentes, quando comparadas à velocidade permitida de 120 km/h. O modelo confirma, portanto, que, quanto maiores as velocidades, maior a probabilidade de ocorrerem acidentes (SWOV, 2012).

Perante os resultados, vê-se que nem sempre o que o modelo prevê está de acordo com o esperado, ou o que seria mais intuitivo de se imaginar. Ressalta-se aqui a importância da elaboração de modelos específicos para a autoestrada que se quer estudar, como foi o caso para a A25. Isto permite abranger as características únicas daquela autoestrada, e os diferentes fenómenos individuais àquele local, que muitas vezes podem estar relacionados a complexas interações entre fatores “ocultos”, como diferente comportamento dos condutores, cultura e clima. Por exemplo, (Pedro, M. *et al.*, 2012) apontam para a influência da geometria das vias nas velocidades praticadas pelos condutores. Outra possibilidade é também o efeito da homogeneidade do traçado, que afeta como os condutores se adaptam à autoestrada (Gomes, S. *et al.*, 2019), que não foram consideradas neste estudo.

4.2. MODELO DE PREVISÃO DE FREQUÊNCIA DE ACIDENTES COM VÍTIMAS (2015-2021)

4.2.1. CONSTRUÇÃO DO MODELO

A elaboração do modelo de previsão de acidentes com vítimas seguiu o mesmo procedimento adotado para os acidentes totais, detalhado no Capítulo 4.1. Em relação aos acidentes totais, ao ser feita a análise exploratória para os acidentes com vítimas, constatou-se que a base de dados teria que ser levemente alterada para melhor adequar-se aos dados dos acidentes. Nomeadamente, a variável velocidade foi agregada em apenas duas categorias, (velocidades menores ou iguais a 100 km/h, ou velocidades de 120 km/h).

O nível de confiança definido para eliminar variáveis explicativas do modelo nos acidentes com vítimas este foi definido a 90%, menos restritivo que para os acidentes totais, eliminando-se apenas as variáveis com valor-*p* maiores que 0,1. Isto foi feito porque, no caso dos acidentes com vítimas, obteve-se relações menos significativas entre as variáveis, provavelmente decorrente do fato dos registos destes tipos de acidentes serem em número mais reduzido. Dessa forma, a opção de diminuir a restrição do nível de significância permitiu incluir mais variáveis no modelo.

Ao analisar as medidas estatísticas do Quadro 13, tanto o modelo com distribuição de Poisson como o BN representaram melhora significativa a incluir as variáveis explicativas para representar o fenómeno, em relação aos modelos apenas com o termo constante, com valores-*p* nulos no teste da razão da verossimilhança.

As comparar as medidas da qualidade de ajuste AIC, BIC e Logaritmo da Verossimilhança dos modelos, vê-se que elas apontam para o melhor ajuste obtido pelo modelo BN, corroborado com o valor parâmetro de sobredispersão obtido. Sendo este valor igual a 1,831 já há um certo distanciamento da distribuição de Poisson, para a qual o parâmetro de sobredispersão seria nulo. Além disso, ao contrário do modelo BN dos acidentes totais, não houve problema de singularidade na matriz Hessiana para o modelo BN dos acidentes com vítimas, tendo-se por fim, optado pelo modelo BN como o melhor representativo dos acidentes com vítimas na A25.

Quadro 12 – Medidas de desempenho do MPA com vítimas (2015-2021).

Estatística de sumarização do modelo	Poisson		Binomial Negativo	
	Valor	Sig. (valor-p)	Valor	Sig. (valor-p)
Razão de Verossimilhança	256	0,000	241	0,000
Qualidade de ajuste do modelo	Valor	Valor/g.l.	Valor	Valor/g.l.
Desviância	1738,852 (6370 g.l.)	0,273	1357,762 (6369 g.l.)	0,213
Chi-quadrado de Pearson	7434,038 (6370 g.l.)	1,167	6781,104 (6369 g.l.)	1,065
AIC	2319,033	-	2290,860	-
BIC	2366,356	-	2344,943	-
Log. da verossimilhança (modelo final)	-1152,517	-	-1137,430	-
Parâmetro de Sobredispersão	-		1,831	

Ao ser feita a modelação no *IBM SPSS*, as variáveis que apresentaram nível de confiança inferiores a 90% foram o número de vias (Num_Vias), existência de equipamento de controlo de velocidade (Radar), largura da berma exterior (BExt), existência de vias suplementares (Outras), largura do separador central (Sep) e Ano, sendo, portanto, eliminadas do modelo. Os parâmetros estimados na regressão Binomial Negativa para os acidentes com vítimas, incluindo apenas as variáveis com significância estatística, estão sumarizados no Quadro 14. O resultado completo obtido no *IBM SPSS* pode ser visto no Anexo C.2.

Quadro 13 – Resultados das estimativas do modelo Binomial Negativo para Acidentes com Vítimas (2015-2021).

Variáveis Explicativas	Descrição	Parâmetro estimado	Desvio padrão	Sig. (valor-p)	Categoria de Referência
LN α	Constante	-23,305	2,228	0,000	-
LN_TMDA	TMDA (log. Natural)	1,692	0,236	0,000	-
LN_Comp	Comprimento do segmento (log. Natural)	1,044	0,082	0,000	-
Raio_C2	Curva Circular ($R \leq 500 $ m)	0,618	0,198	0,002	Curva Circular ($ 500 $ m < $R \leq 900 $ m)
Vel_C0	≤ 100 km/h	-0,284	0,138	0,040	120 km/h
Sent_C0	Sentido Crescente	-0,329	0,126	0,009	Sentido Decrescente
Φ	Parâmetro de Sobredispersão	1,831	0,508	-	-

A partir da Equação 4, utilizando as variáveis com significância e os parâmetros estimados para os acidentes com vítimas, chegou-se à equação final do modelo:

$$E[y] = 7,56 \times 10^{-11} TMDA^{1,692} Comp^{1,044} e^{0,618 Raio_{C2} - 0,284 Vel_{C0} - 0,329 Sent_{C0}} \quad (26)$$

Sendo:

- *TMDA* – tráfego médio diário anual do segmento [veic./dia];
- *Compr* – o comprimento do segmento [m];
- *Raio* – categoria do raio do segmento (em que C2 equivale a curvas circulares de raio menor ou igual 500 m);
- *Vel* – categoria referente ao limite de velocidade de circulação permitido no segmento (sendo C0 os limites de velocidade inferiores ou iguais a 100 km/h);
- *Sent* – categoria referente ao sentido de circulação na autoestrada (C0 corresponde ao sentido crescente).

4.2.2. VALIDAÇÃO REPLICATIVA

De forma idêntica ao procedimento efetuado para os acidentes totais, fez-se a avaliação gráfica do modelo de acidentes com vítimas. Foi criado o gráfico dos resíduos acumulados para valores crescentes variáveis de exposição pelo método CURE, com os resíduos dos 7 anos (2015-2021) utilizados na construção do modelo.




Fig. 22 – Gráfico dos resíduos acumulados dos acidentes com vítimas (2015-2021) para a variável TMDA [veíc./dia] – modelo 7 anos.




Fig. 23 – Gráfico dos resíduos acumulados dos acidentes com vítimas (2015-2021) para a variável comprimento [m] – modelo 7 anos.

Ambos os gráficos demonstram que o modelo de acidentes com vítimas se ajusta muito bem aos dados. No gráfico para o TMDA (Figura 22), os resíduos respeitam quase na sua totalidade as bandas delimitadoras definidas por $\pm 2\sigma$, excedendo-as apenas para segmentos com TMDA próximo de 7380 e 7400, e acima de 8400 veíc. /dia. Além disso, a curva oscila bem em torno do eixo horizontal, terminando em valores próximos do zero.

Os gráficos dos resíduos acumulados para o comprimento (Figura 23) também mostram resultados satisfatórios do ajuste do modelo para esta variável. Apesar da curva exceder ligeiramente o limite de –

2σ para os segmentos mais curtos e com cerca de 150 m, e o limite de $+2\sigma$ nos maiores segmentos e nos com cerca de 500 m, a curva oscila em torno do eixo horizontal e retorna para valores próximos de 0.

No geral, é possível concluir da boa qualidade de ajuste do modelo, ou seja, o modelo é uma boa réplica da realidade.

4.2.3. INTERPRETAÇÃO DO EFEITO DAS VARIÁVEIS EXPLICATIVAS NOS ACIDENTES COM VÍTIMAS

Foi seguido o mesmo processo abordado no Capítulo 4.1.3. para analisar o efeito que as variáveis explicativas geram, individualmente, nos acidentes com vítimas. Utilizou-se de novo o conceito de elasticidade e pseudo-elasticidade para perceber a influência (positiva ou negativa) que as variáveis contínuas e *dummy*, respetivamente, exercem na variável de resposta.

As elasticidades das variáveis de exposição TMDA e comprimento e estão representadas no Quadro 16.

Quadro 14 – Elasticidade de aumentos de 10% nas variáveis contínuas na probabilidade de acidentes – MPA com vítimas (2015-2021).

Variável	Parâmetro estimado	Elasticidade	Aumento/Diminuição da probabilidade de Acidentes
TMDA	1,692	1,692	17%
Comprimento	1,044	1,044	10%

Para os acidentes com vítimas, o comprimento do segmento apresentou uma relação ainda mais próxima da linear que para os acidentes totais, com um aumento de 10% do risco de acidentes resultante de um aumento em 10% da extensão.

À semelhança dos acidentes com totais, um aumento em 10% do TMDA aumenta em 17% a probabilidade de ocorrerem acidentes com vítimas, corroborando mais uma vez com o encontrado na literatura, como é o caso do estudo de Yu, R. e Abdel-Aty, M. (2013).

Os resultados dos cálculos da Pseudo-elasticidade das variáveis *dummy* estão expostos no Quadro 16.

Quadro 15 – Pseudo-Elasticidade das variáveis dummy – Acidentes com Vítimas.

Variável (Código)	Descrição	Parâmetro estimado	Pseudo-Elasticidade	Aumento/Diminuição do Risco de Acidentes	Comparando com
Raio_C2	Curva Circular ($R \leq 500 $ m)	0,618	0,461	46%	Curva Circular ($ 500 \text{ m} < R \leq 900 \text{ m}$)
Vel_C0	≤ 100 km/h	-0,284	-0,329	-33%	120 km/h
Sent_C0	Sentido Crescente	-0,329	-0,390	-39%	Sentido Decrescente

No caso da variável Raio, a categoria Raio_C1 (segmentos com reta, curva de transição ou curvas circulares com raios maiores que 900 m) não apresentou significância estatística. Já a categoria Raio_C2

(segmentos em curva circular de raios menores ou iguais a 500 m) apresentou o mesmo valor de elasticidade exibido nos acidentes totais (Quadro 14), representando um aumento de 46% do risco de acidentes com vítimas, em relação a curvas circulares de maior raio.

Os segmentos com velocidades máximas permitidas menores ou iguais a 100 km/h (Vel_C0) têm uma redução da probabilidade de acidentes com vítimas de 33% em relação aos segmentos cujas velocidades permitidas são de 120km/h.

O resultado para a variável Sentido (Sent) indica que as viagens realizadas no sentido crescente da A25 (Sent_C0), isto é, Aveiro – Vilar Formoso, têm 39% menos risco de gerar acidentes com vítimas, quando comparadas com as viagens no sentido decrescente. É possível que o sol, ao se pôr, afete a visibilidade dos condutores que vão no sentido Este – Oeste (sentido decrescente da A25), gerando maiores ocorrências neste sentido.

4.3. AVALIAÇÃO DA CAPACIDADE PREDITIVA DOS MODELOS

A fim de aferir de forma mais robusta a capacidade de previsão dos modelos, obtendo assim maior fiabilidade dos resultados de previsão, seguiu-se com outra fase de análise gráfica. Estas análises constituem um tipo de validação, que consistiu em utilizar 5 anos para a modelação e 2 anos para a previsão, de forma a testar o modelo para dados que não foram utilizados na sua calibração. Com isso, é feita a comparação dos valores dos acidentes observados com os valores previstos pelos modelos, para tirar conclusões acerca da capacidade de o modelo prever os acidentes com proximidade à realidade.

A validação foi feita tanto para os acidentes totais, como para os acidentes com vítimas, para os quais os dados dos anos de 2015 a 2019 foram usados para modelação (modelo com 5 anos), e a previsão foi feita para os anos de 2020 e 2021. O gráfico dos resíduos acumulados pelo método CURE foi novamente utilizado para analisar a proximidade dos acidentes previstos com os observados.

Visto que o método se resume a tirar conclusões acerca do modelo completo (7 anos) com base no modelo com 5 anos, fez-se uma etapa intermediária para avaliar a semelhança entre os dois modelos. Esta etapa passou pela comparação entre os resíduos acumulados dos anos de 2015 a 2019 dos modelos feitos para 7 anos (Capítulos 4.1 e 4.2) e para os 5 anos, de forma a verificar se os padrões dos resíduos dos gráficos feitos para ambos os modelos são semelhantes. Caso afirmativo, concluiu-se que era coerente seguir para a avaliação da capacidade de previsão dos modelos de 7 anos.

4.3.1. MODELO DE FREQUÊNCIA DE ACIDENTES TOTAIS (2015-2019)

Para realizar a modelação com os dados com apenas 5 anos, foram consideradas as mesmas variáveis e distribuição do modelo de 7 anos (Capítulo 4.1). Neste caso, ao considerar somente variáveis com níveis de confiança maiores que 95%, a variável velocidade (Vel) deixou de ter significância estatística.

O resultado dos parâmetros estimados na regressão de Poisson para o modelo com dados de 2015 a 2019 está sumarizado no Quadro 17. O resultado completo obtido no *IBM SPSS* pode ser visto no Anexo C.3.

Quadro 16 – Resultados das estimativas do modelo de Poisson para acidentes totais (2015-2019).

Variáveis Explicativas	Descrição	Parâmetro estimado	Desvio padrão	Sig. (valor-p)	Categoria de Referência
LN α	Constante	-21,084	1,418	0,000	-
LN_TMDA	TMDA (log. Natural)	1,632	0,150	0,000	-
LN_Compr	Comprimento do segmento (log. Natural)	0,870	0,052	0,000	-
Raio_C1	Curva Circular (R > 900 m) /Reta/Clotóide	0,243	0,111	0,028	Curva Circular (500 m < R ≤ 900 m)
Raio_C2	Curva Circular (R ≤ 500 m)	0,632	0,127	0,000	
Outras_C1	Via de Aceleração/Desaceleração	-0,616	0,180	0,001	Não existem vias suplementares
Outras_C3	Via de Lentos & Via de Aceleração/Desaceleração	-0,776	0,339	0,022	
Sep_C0	Separador Central de 0,6 m	0,308	0,078	0,000	Separadores Centrais ≥ 4 m

Com o valor dos parâmetros estimados, chega-se à equação final do modelo de previsão de frequência de acidentes totais, sendo $E[y]$ o valor estimado de acidentes totais por ano, num determinado segmento:

$$E[y] = 6,97 \times 10^{-10} TMDA^{1,632} Compr^{0,870} e^{0,243 Raio_{C1} + 0,632 Raio_{C2} - 0,616 Outras_{C1} - 0,776 Outras_{C3} + 0,308 Sep_{C0}} \quad (27)$$

Sendo:

- *TMDA* – tráfego médio diário anual do segmento;
- *Compr* – o comprimento do segmento;
- *Raio* – categoria do raio do segmento (em que C1 equivale a curvas circulares de raio maior que 900 m, ou clotóide ou reta, e C2 equivale a curvas circulares de raio menor ou igual 500 m);
- *Outras* – categoria do tipo de via suplementar existente no segmento (em que C1 equivale a via de aceleração e/ou desaceleração, e C3 condiz a via de aceleração ou desaceleração e via de lentos, em simultâneo);
- *Sep* – categoria referente à largura do separador central no segmento (C0 equivale a separadores centrais com largura de 0,6 m)

Em seguida procedeu-se à elaboração dos gráficos dos resíduos acumulados dos acidentes totais para o TMDA e o comprimento, dos anos 2015 a 2019, tanto para os valores previstos pela aplicação do modelo de 7 anos (Equação 25) como para os valores previstos pelo modelo de 5 anos (Equação 27). Os resultados estão representados no Anexo D.1.

Dos resultados no Anexo, vê-se que os resíduos acumulados seguem um padrão de picos semelhante, e para valores quase iguais de TMDA e comprimento. Desta forma, é possível inferir que o modelo de 5 anos representa bem o modelo de 7 anos, e é dada continuidade à análise da capacidade de previsão do modelo, detalhada a seguir.

Utilizando a equação do modelo de 5 anos, fez-se a previsão dos acidentes totais dos anos de 2020 e 2021, que foram comparados com os valores observados. Seguindo a mesma metodologia do método CURE feita na validação replicativa, os gráficos dos resíduos acumulados foram criados para os 2 anos, em valores crescentes das variáveis de exposição TMDA e comprimento.




Fig. 24 – Gráfico dos resíduos acumulados dos acidentes totais (2020) para a variável TMDA [veíc./dia] – modelo 5 anos.




Fig. 25 – Resíduos Acumulados dos acidentes totais (2020) para a variável comprimento [m] – modelo 5 anos.

Nas Figuras 24 e 25, são apresentados os gráficos dos resíduos acumulados do ano 2020, para as variáveis TMDA e comprimento, respetivamente. Da Figura 24, é possível observar que a curva para o TMDA oscila em torno do eixo horizontal e termina próxima de 0. O limite definido por $\pm 2\sigma$ é respeitado na maioria dos casos, com exceção para valores de TMDA em torno de 4800 veículos por dia, e 6980 veíc./dia, onde houve uma sobrestimação dos acidentes.

A Figura 25 revela que para a variável comprimento, os valores também oscilam em torno do eixo horizontal e terminam próximos do valor nulo. A curva ultrapassa a banda delimitadora em poucos casos, sobretudo para segmentos com extensões em torno de 120 e 145 m, e segmentos mais extensos (2400 e 2600 m). No geral, nota-se que de facto, apesar de 2020 ter sido um ano atípico devido à pandemia Covid-19, o modelo fez previsões adequadas dos acidentes totais, o que corrobora com os resultados obtidos por Ribeiro, J. (2021).




Fig. 26 – Resíduos Acumulados da variável TMDA para acidentes Totais (2021) – modelo 5 anos.




Fig. 27 – Resíduos Acumulados da variável Comprimento para acidentes Totais (2021) – modelo 5 anos.

As Figuras 26 e 27 mostram o gráfico dos resíduos acumulados para as variáveis TMDA e comprimento, respetivamente, para o ano de 2021. Diferente do que se pôde concluir para o ano de 2020, é notável que o modelo não previu adequadamente os acidentes do ano 2021, com exceção de valores de TMDA menores e extensões mais pequenas, nomeadamente, para segmentos com TMDA abaixo de 4300

veíc./dia e extensões abaixo de 215 metros. Em geral, ao ultrapassar o limite -2σ , há uma consistente sobrestimação dos acidentes, para maiores valores de TMDA e comprimento.

Enquanto o efeito da pandemia Covid-19 pode não ter impactado a relação entre os acidentes totais e as variáveis explicativas em 2020 na autoestrada A25, é possível que o mesmo pressuposto não se aplique ao ano de 2021. Isto é, enquanto a redução de acidentes totais no ano de 2020 teve uma relação quase direta com a redução do tráfego, resultado de medidas restritivas de circulação, a mudança no número de acidentes em 2021 pode ser resultado de fatores menos diretos que a simples mudança do TMDA.

Efetivamente, constata-se na Figura 14 do Capítulo 3.2.2. que na autoestrada em estudo houve uma queda abrupta tanto do TMDA quando dos acidentes totais em 2020. Por outro lado, em 2021, ainda que não tenha se estabelecido aos níveis pré-Covid, o TMDA aumentou, e o número de acidentes totais não acompanhou este crescimento, tendo aumentado mais lentamente.

Em suma, salvo o ano de 2021, considera-se que o modelo de acidentes totais é capaz de fazer boas previsões, e com isso seguiu-se com sua transformação numa ferramenta de suporte à decisão na SR, que será detalhada no Capítulo 5.

4.3.2. MODELO DE FREQUÊNCIA DE ACIDENTES COM VÍTIMAS (2015-2019)

Na elaboração do modelo de acidentes com vítimas apenas com os dados dos primeiros 5 anos, nenhuma variável considerada no modelo de 7 anos perdeu significância estatística (para níveis de confiança de 90%).

A regressão Binomial Negativa foi igualmente utilizada para o modelo com menos dados, resultando nos parâmetros estimados representados no Quadro 18. O resultado completo obtido no *IBM SPSS* pode ser visto no Anexo C.4.

Quadro 17 – Resultados das estimativas do modelo Binomial Negativo para acidentes com vítimas (2015-2019).

Variáveis Explicativas	Descrição	Parâmetro estimado	Desvio padrão	Sig. (valor-p)	Categoria de Referência
LN α	Constante	-22,115	2,595	0,000	-
LN_TMDA	TMDA (log. Natural)	1,573	0,275	0,000	-
LN_Compr	Comprimento do segmento (log. Natural)	0,995	0,093	0,000	-
Raio_C2	Curva Circular ($R \leq 500 $ m)	0,741	0,232	0,001	Curva Circular ($ 500 $ m < $R \leq 900 $ m)
Vel_C0	≤ 100 km/h	-0,288	0,158	0,069	120 km/h
Sent_C0	Sentido Crescente	-0,297	0,143	0,038	Sentido Decrescente
Φ	Parâmetro de Sobredispersão	1,666	0,557	-	-

Sendo assim, o valor esperado de acidentes com vítimas, com base no modelo de 2015 a 2019 é dado por:

$$E[y] = 2,49 \times 10^{-10} TMDA^{1,573} Comp^{0,995} e^{0,741 Raio_{C2} - 0,288 Vel_{C0} - 0,297 Sent_{C0}} \quad (28)$$

Sendo:

- *TMDA* – tráfego médio diário anual do segmento;
- *Compr* – o comprimento do segmento;
- *Raio* – categoria do raio do segmento (em que C2 equivale a curvas circulares de raio menor ou igual 500 m);
- *Vel* – categoria referente ao limite de velocidade de circulação permitido no segmento (sendo C0 os limites de velocidade inferiores ou iguais a 100 km/h);
- *Sent* – categoria referente ao sentido de circulação na autoestrada (C0 corresponde ao sentido crescente).

De forma a averiguar se seria possível concluir acerca da capacidade de previsão do modelo completo (7 anos) a partir do modelo de 5 anos, seguiu-se para a etapa prévia à validação propriamente dita. Para tal, foram elaborados os gráficos dos resíduos acumulados dos acidentes com vítimas de 2015 a 2019 com o modelo de 5 anos (Equação 28) e com o modelo de 7 anos (Equação 26). Caso seja perceptível uma semelhança no padrão dos gráficos, deduz-se que o modelo com menos dados (5 anos) representa adequadamente o modelo com todos os dados (7 anos), e por isso, é razoável utilizar o primeiro para avaliar a capacidade de previsão do segundo.

Os gráficos mencionados acima se encontram no D.2. Acidentes com Vítimas Embora modelo de 7 anos apresente um bom ajuste aos dados de 2015 a 2019, o modelo de 5 anos não se ajustou bem aos dados dos mesmos anos. Para a variável TMDA, o modelo de 5 anos apresentou resíduos que apenas excederam em excesso os limites definidos $\pm 2\sigma$ para valores acima de 7000 veíc. / dia. Entretanto, a oscilação ocorreu acima do eixo horizontal, o que escapou do padrão desejado.

Para a variável comprimento, o CURE do modelo de 5 anos (D.2.4. Resíduos Acumulados Acidentes com Vítimas (2015-2019) Para o Comprimento – Previsão do Modelo 5 Anos) evidenciou ainda mais o desajuste para maiores valores da variável, neste caso, subestimando os acidentes nos segmentos maiores que 420 m. Por outro lado, antes de exceder o limite $+2\sigma$, a curva oscilou razoavelmente em torno do eixo horizontal, representando em geral, bom ajuste para comprimentos menores que 420 m, aproximadamente.

Sendo assim, pelo facto de o modelo de 5 anos não ter boa qualidade de ajuste para maiores valores das variáveis de exposição, considerou-se que o modelo de 5 anos não seria fiável para testar a capacidade de previsão do modelo completo. Por essa razão, não se prosseguiu com a avaliação da capacidade de previsão do modelo de acidentes com vítimas.

Face a isso, optou-se por não fazer uma aplicação prática do modelo de acidentes com vítimas. Entretanto, tendo sido os resíduos acumulados do modelo de 7 anos bem ajustados aos dados (validade replicativa), a interpretação dos fatores de risco relacionados aos acidentes com vítimas, feita no Capítulo 4.2.2. continua a ser válida.

5

APLICAÇÃO DO MODELO

5.1. PREVISÃO DOS ACIDENTES TOTAIS PARA UM CENÁRIO HIPOTÉTICO

Para além da identificação dos fatores de risco associados aos acidentes na A25, feita no Capítulo 4, foram feitas outras aplicações práticas dos modelos.

Assim, o modelo de acidentes totais (MPA totais 2015-2021) foi aplicado para estimar o número de acidentes previstos por segmento para 2023, num cenário que considerou as projeções internas do TMDA para o mesmo ano.

Adicionalmente, e de forma a comparar uma estratégia reativa com a estratégia proativa feita neste trabalho, fez-se a avaliação dos locais críticos selecionados pelo MPA vs. a avaliação baseada apenas nos dados históricos dos acidentes.

As figuras a seguir ilustram a estimativa de evolução do tráfego, com base na projeção feita pela Ascendi. Salienta-se que o TMDA previsto para 2023 foi considerado igual para o sentido crescente e decrescente, não tendo sido possível obter a projeção por sentido. Entretanto, para o fim que se pretende obter com a previsão, isso não foi um obstáculo, visto que o TMDA normalmente não diverge muito entre os sentidos.

Destaca-se a relevância de se utilizar a projeção de tráfego, de forma a obter um cenário mais realístico para previsão dos acidentes. Como é possível ver nas Figuras 28 e 29, os sublanços com maiores/menores evoluções estimadas no TMDA para 2023 não são necessariamente aqueles com maiores/menores valores médios entre 2015 e 2021.




Fig. 28 – Análise da evolução (projetada) do TMDA em 2023, em relação à média dos anos 2015-2021, para o sentido crescente da A25.




Fig. 29 – Análise da evolução (projetada) do TMDA em 2023, em relação à média dos anos 2015-2021, para o sentido decrescente da A25.

A análise foi feita para os sublanços, tendo maior interesse prático para a Ascendi. Utilizando a equação do modelo de acidentes totais dos 7 anos (Equação 25), fez-se a previsão dos acidentes totais para cada um dos 911 segmentos, alterando-se apenas os valores do TMDA, para o projetado do ano de 2023.

5.1.1. ANÁLISE DOS ACIDENTES NOS SUBLANÇOS EM 2023

Após a afetação do TMDA projetado para 2023 a seus respectivos segmentos, os acidentes totais em 2023 foram estimados para cada um dos segmentos naquele ano. Os resultados obtidos para os segmentos permitem que a análise seja feita por sublanços, sendo os acidentes previstos em 2023 para cada sublanço igual ao somatório os acidentes previstos para cada segmento a ele pertencente.

Nas Figuras 30 e 31, está ilustrada a comparação entre a média observada de acidentes totais entre 2015 e 2021, e os valores previstos dos acidentes totais em 2023, por sublanço, para os sentidos crescente e decrescente, respetivamente. Os valores foram arredondados a uma casa decimal.

Estima-se que o maior número de acidentes totais em 2023 ocorra no sublanço Carvoeiro-Talhadas no sentido crescente, com cerca de 10 acidentes. Em seguida, está o sublanço Talhadas-Reigoso, sentido decrescente, com cerca de 9 acidentes esperados, e o Carvoeiro-Talhadas, sentido decrescente, também com cerca de 9 acidentes.




Fig. 30 – Comparação entre os acidentes totais previstos para o ano 2023, por sublanço, e a média histórica (2015-2021), sentido crescente.




Fig. 31 – Comparação entre os acidentes totais previstos para o ano 2023, por sublânço, e a média histórica (2015-2021), sentido decrescente.

De forma a perceber a diferença entre a escolha dos locais para tratamento de forma reativa e de forma preventiva, fez-se a comparação dos sublânços identificados como mais perigosos pelas duas estratégias. O Quadro 19 mostra os 10 sublânços (por sentido) cujo modelo prevê que tenham mais acidentes em 2023. Além disso, é feita em paralelo a relação entre a posição de cada sublânço na ordem de maior número de acidentes previstos para 2023, com a posição que estes sublânços ocupavam no ranking de maior média observada entre 2015 e 2021.

Este último ranking constitui uma estratégia reativa, e muito comumente utilizada para seleção de locais para melhoria da SR, na qual a atenção é dada aos locais que vêm registado mais acidentes. Embora possa ser útil, esta metodologia (e.g. as estratégias mais comuns de identificação de ZAAs e pontos negros) necessita que existam acidentes para que seja tomada a iniciativa, e à medida que estes estão mais escassos, essa estratégia perde sua eficácia.

Os resultados dos rankings de acidentes pela previsão e pela média de acidentes observados, para todos os sublânços se encontram no Anexo E.

Quadro 18 – Identificação dos sublanços da A25 para melhoria da SR. Medida proativa vs. reativa.

Posição	Localização	Sentido	Previsão Acidentes Totais 2023	Média observada Acidentes Totais (2015-2021)	Posição no ranking da média observada Acidentes Totais (2015-2021)
1º	Carvoeiro - Talhadas	SC	10,3	6,3	3º
2º	Talhadas - Reigoso	SD	9,1	5,3	7º
3º	Carvoeiro - Talhadas	SD	8,9	14,0	1º
4º	Talhadas - Reigoso	SC	7,6	2,9	18º
5º	Caçador - Fagilde	SC	6,8	6,9	2º
6º	Caçador - Fagilde	SD	6,5	5,6	6º
7º	Fornos de Algodres - Celorico	SC	6,0	5,9	5º
8º	IP2/A25 - Guarda	SD	5,9	3,4	15º
9º	IP2/A25 - Guarda	SC	5,9	2,3	23º
10º	Mangualde - Chãs de Tavares	SC	5,8	2,0	29º

Constata-se com o quadro que os locais possíveis de ser selecionados para melhoria da SR diferem entre uma metodologia (proativa) e outra (reativa). Para os dez sublanços com maior número previsto de acidentes totais em 2023, apenas o sublanço Caçador – Fagilde no sentido decrescente teria o mesmo nível de prioridade em ambas as metodologias.

Já os sublanços Carvoeiro – Talhadas (crescente); Talhadas – Reigoso (decrecente e crescente); IP2/A25 – Guarda (decrecente e crescente) e Mangualde – Chãs de Tavares (crescente) subiram em nível de prioridade para tratamento, ao comparar com os sublanços que teriam prioridade na seleção feita pela estratégia reativa. Destaque para Mangualde – Chãs de Tavares (crescente), que teve o maior salto na classificação, indo da 29ª posição na média histórica de acidentes (2015-2021), para a 10ª posição no valor esperado de acidentes (2023). Por outro lado, os sublanços Carvoeiro – Talhadas (decrecente); Caçador – Fagilde (crescente) e Forno de Algodres – Celorico (crescente), perderiam prioridade ao ser selecionados de maneira proativa.

Vê-se ainda que, embora o TMDA esteja projetado para aumentar em todos os sublanços, nalguns casos, o número previsto de acidentes para 2023 foi menor do que a média observada nos últimos anos. Isto é ainda mais claro em Carvoeiro – Talhadas (decrecente), em que a média foi de 14 acidentes, enquanto o modelo prevê cerca de 8,9 acidentes.

É de mencionar que a identificação das zonas para intervenção de maneira reativa utilizada na comparação considerou os dados históricos dos acidentes, e por isso, assim como na identificação pelo MPA, considerou o efeito da variação aleatória dos acidentes. Sendo assim, é de se esperar que a utilização do MPA, em comparação com estratégias reativas que considerem apenas os acidentes a curto prazo, gere ainda mais diferenças nos locais selecionados para intervenção.

5.1.2. CONSIDERAÇÕES FINAIS

Como foi visto anteriormente, aplicação do modelo pode trazer *informações* importantes acerca da segurança na autoestrada em questão. De forma análoga, uma análise mais particularizada pode ser feita ao avaliar os acidentes nos segmentos ao invés dos sublanços. Vale ressaltar que não é esperado, nem necessariamente há grande ganho em obter estimativas exatas dos números esperados de acidentes, dado o fim a que são propostos os modelos. Ainda, o critério dos *rankings* serve apenas como um indicador, que, entretanto, deve ser analisado caso a caso, pois haverá sublanços/segmentos que diferem apenas em décimas no número de acidentes previstos, enquanto na prática não faz sentido privilegiar um ao outro. Nestes casos, convém avaliar outros fatores que sirvam como critério de desempate, como o número de acidentes com vítimas previsto em cada sublanço/segmento.

Naturalmente, as maiores mudanças na autoestrada entre um ano e outro ocorrem no TMDA, tendo sido o motivo pelo qual a aplicação centrou-se na mudança de valores unicamente desta variável explicativa, mantendo inalterados os valores das restantes variáveis.

Entretanto, este tipo de análise pode ser feito para diversos cenários, ficando esta escolha à critério das entidades rodoviárias, em função de quais tipos de mudanças que pretendem avaliar o efeito na SR. Para tal, basta que estas variáveis estejam incluídas no modelo, fazendo-se a alteração dos valores da variável que se pretende analisar e calculando novamente o valor esperado dos acidentes por meio da equação do modelo.

Ainda, de forma a aumentar a robustez estatística dos modelos, para que as aplicações tragam resultados mais fiáveis, é importante atualizar a base de dados dos modelos com os dados dos anos que sucedem, especialmente dos acidentes. Estes dados devem ser inseridos na base de dados por meio da replicação dos segmentos para mais um ano, seguido da afetação dos acidentes (ou dados de outras variáveis) a seus respectivos segmentos. Em seguida, faz-se a calibração do modelo para os novos dados e é dado seguimento à sua aplicação.




Fig. 32 – Etapas recomendadas para atualização dos MPAs.

6 CONCLUSÕES

A acidentes rodoviários são uma preocupação a nível mundial, mesmo nos países que já reduziram consideravelmente a sinistralidade por meio de esforços voltados para a segurança rodoviária. Nestes casos, o problema tem se dado pelo facto das estratégias utilizadas perderem a eficiência à medida que os acidentes se tornam cada vez mais escassos.

Visando contornar esse problema, faz-se necessário o uso de abordagens sistemáticas de forma a atingir a ambiciosa meta de reduzir a zero o número de mortos e feridos graves nas estradas. Neste contexto, os modelos de previsão de acidentes apresentam grande utilidade, uma vez que permitem obter a relação entre os fatores de risco e os acidentes, e com isso atuar preventivamente, e de maneira otimizada na sua redução.

O principal objetivo deste trabalho foi atingido, no qual foram elaborados modelos de previsão frequência de acidentes para a autoestrada A25 e que permitiram a identificar e quantificar o efeito de características geométricas e operacionais das vias no risco de acidentes. Nomeadamente, foram criados dois modelos estatísticos do tipo linear generalizado, para segmentos em plena via, com dados dos anos 2015 a 2021.

O primeiro modelo teve como variável dependente os acidentes totais, e o segundo os acidentes com vítimas, aos quais as distribuições de Poisson e BN foram respetivamente, as mais adequadas. A qualidade de ajuste dos modelos foi verificada por métricas de desempenho e o gráfico dos resíduos acumulados para as variáveis de exposição (TMDA e comprimento), mostrando qualidade em ambos os modelos.

Conseguiu-se ainda abordar em detalhe o processo de segmentação. O critério de segmentação adotado considerou um número reduzido de critérios para definir um troço homogéneo, de forma a reduzir o número de segmentos com extensões muito curtas, e suscetíveis de um mal ajuste/enviesamento do modelo, nomeadamente nesses troços. Entretanto, face aos critérios que se pretendiam utilizar, não foi possível eliminar completamente alguns segmentos de extensão mais reduzida.

Com os resultados obtidos na modelação, foram verificadas as seguintes relações entre os acidentes na A25 e as suas características viárias (Quadros 21 e 22):

Quadro 19 – Relações encontradas entre as características geométricas, de perfil transversal e operacionais da A25 (BLA) e os acidentes totais.

Variável	Fator de Risco	Comparando com	Aumento/diminuição da probabilidade de acidentes totais
TMDA	Aumento em 10% do Tráfego médio diário anual no segmento [veíc./dia]	-	17%
Comprimento	Aumento em 10% da extensão do segmento [m]	-	9%
Raio	Curva Circular $R > 900 $ m ou clóide ou reta	Curva circular $ 500 $ m $< R \leq 900 $ m	18%
Raio	Curva circular $R \leq 500 $ m	Curva circular $ 500 $ m $< R \leq 900 $ m	46%
Outras vias	Presença de via de aceleração e/ou desaceleração	Não existência de vias suplementares	-92%
Outras vias	Presença de via de aceleração ou desaceleração & via de lentos	Não existência de vias suplementares	-136%
Separador Central	Segmento com separador central de 0,6 m de largura	Segmento com separador central com 4 m ou mais de largura	20%
Velocidade	Limite de velocidade permitido menor que 100 km/h	Limite de velocidade permitido de 120 km/h	-714%
Velocidade	Limite de velocidade permitido igual a 100 km/h	Limite de velocidade permitido de 120 km/h	-16%

Quadro 20 – Relações encontradas entre as características geométricas, de perfil transversal e operacionais da A25 (BLA) e os acidentes com vítimas.

Variável	Fator de Risco	Comparando com	Aumento/diminuição da probabilidade de acidentes com vítimas
TMDA	Aumento em 10% do Tráfego médio diário anual no segmento [veíc./dia]	-	17%
Comprimento	Aumento em 10% da extensão do segmento [m]	-	10%
Raio	Curva circular $R \leq 500 $ m	Curva circular $(500 $ m $< R \leq 900 $ m)	46%
Velocidade	Limite de velocidade permitido menor ou igual 100 km/h	Limite de velocidade permitido de 120 km/h	-33%
Sentido	Sentido crescente de viagem	Sentido decrescente de viagem	-39%

A etapa de validação para testar a capacidade de previsão modelos consistiu na sua calibração com dados de 2015 a 2019, para previsão dos anos de 2020 e 2021 e análise dos gráficos dos resíduos acumulados para os 2 anos.

A análise gráfica do MPA totais revelou que o modelo prevê bem os acidentes do ano 2020, enquanto para o ano de 2021 ocorre superestimação dos acidentes para valores mais elevados de TMDA e comprimento. É possível que nesse ano, ainda sob efeitos da pandemia do Covid-19, diversos fenómenos tenham acarretado em mudanças na condução e a consequente mudança da relação entre o TMDA e os acidentes, embora em 2020 as restrições de circulação (para contenção do vírus) possa ter gerado diminuição dos acidentes mais proporcional à diminuição do volume de tráfego. Sendo assim, considerou-se que o modelo, à exceção de 2021, consegue fazer previsões aproximadas da realidade, seguindo-se com sua aplicação.

Já na análise gráfica do MPA com vítimas, uma etapa intermédia de comparação do modelo com dados de 7 anos com o modelo de 5 anos (2015 a 2019) mostrou que o modelo de 5 anos não se assemelha do modelo original. Tendo isso em vista, não foi dado seguimento à análise gráfica de 2020 e 2021, e por essa razão não foi possível avaliar a capacidade de previsão do modelo, nem o utilizar para uma aplicação prática com a garantia que produzisse resultados fiáveis.

A aplicação prática do modelo de acidentes totais para um cenário alternativo foi feita com sucesso, na qual o MPA totais (2015-2021) foi utilizado para prever os acidentes, por segmento, em 2023, considerando a projecção do TMDA para o mesmo ano. Posteriormente, fez-se a classificação dos sublanços mais perigosos, com base nos acidentes estimados, e também foi feita a comparação da classificação baseada na média de acidentes registados para elucidar a diferença entre uma abordagem proactiva e outra reativa na seleção de locais para melhoria. Uma síntese do trabalho efetuado é representada na Figura 33.

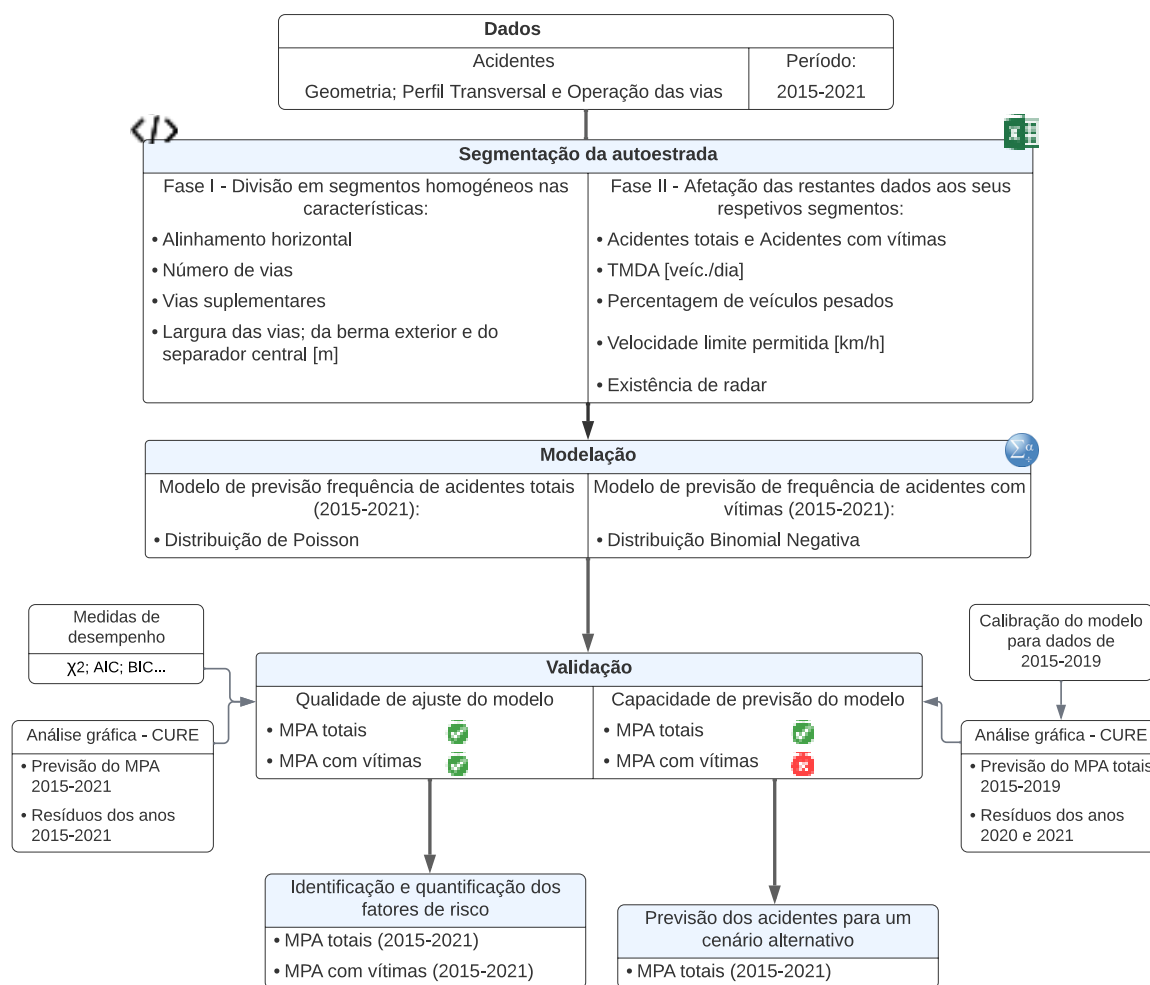


Fig. 33 – Síntese do trabalho.

Limitações

Sem prejuízo do esforço na automatização do tratamento da informação, os dados disponíveis não estão organizados da forma mais apropriada para construção da base de dados necessária para o estudo, o que dificulta o processo de segmentação e afetação das variáveis aos segmentos. A omissão e indicação equívoca de alguns dados também dificultou a segmentação da rede e acarretou em considerável tempo despendido na verificação dos erros e sua correção.

Por fim, a velocidade operacional provavelmente seria relevante nos modelos, entretanto não foi utilizada pois seria necessária a recolha exaustiva destes dados em vários de pontos da A25 que não era compatível com o tempo disponível para a realização deste trabalho.

Recomendações e perspectivas futuras

Recomenda-se a uniformização na forma como os dados são disponibilizados, padronização das nomenclaturas utilizadas e correção dos dados omissos de forma a apoiar o processo da segmentação e reduzir o tempo despendido na construção da base de dados para os modelos.

Dessa maneira, conseguir-se-ia avaliar o ajuste dos modelos para diferentes formas de segmentação, o que seria oportuno para tentar melhorar os resultados do MPA com vítimas em termos da capacidade de previsão, bem como expandir a criação de modelos a outras autoestradas.

Aconselha-se ainda a recolha de dados das velocidades operacionais de forma a incluí-las como uma variável do modelo, de forma a torná-los ainda mais explicativos da realidade.

Adicionalmente, seria de interesse realizar mais aplicações práticas ao modelo de acidentes totais, supondo mudanças no *design* da A25, ajudando, por exemplo, à análise do custo-benefício dessas alterações.

Por fim, futuramente, a base de dados deve ser atualizada com dados de novos anos, refazendo-se a calibração dos modelos desenvolvidos, de forma a garantir uma maior robustez dos mesmos.

Espera-se que os resultados alcançados neste trabalho apoiem a SR na Ascendi quanto à seleção de locais e medidas que visem reduzir a sinistralidade rodoviária, de forma que os resultados das intervenções sejam mais efetivos, além de otimizar a alocação dos recursos. Complementarmente, almeja-se disseminar os resultados e tornar as ferramentas desenvolvidas mais amigáveis aos utilizadores, de forma a facilitar sua utilização e contribuir para contínua melhoria e expansão da adoção dos modelos a outras autoestradas.

REFERÊNCIAS BIBLIOGRÁFICAS

- Ambros, J., Jurewicz, C., & Turner, S. (2017). Research vs. practice: An international review of challenges and opportunities in development and use of crash prediction models. *2017 Australasian Road Safety Conference*. Perth, Australia.
- Ambros, J., Jurewicz, C., Turner, S., & Kieć, M. (2018). An international review of challenges and opportunities in development and use of crash prediction models. *European Transport Research Review*.
- American Association of State and Highway Transportation Officials AASHTO. (2010). *Highway Safety Manual*. Washington, USA.
- Ascendi. (2021). *Plano de Ação de Segurança Rodoviária 2020-2023*.
- Ascendi. (2022). *Anuário de Segurança Rodoviária 2021*.
- Autoridade Nacional de Segurança Rodoviária ANSR. (2020). *Visão Zero 2030: Princípios balizadores da estratégia nacional de segurança rodoviária*.
- Azeredo Lopes, S., & Cardoso, J. L. (2007). *Accident Prediction Models for Portuguese Single Carriageway Roads*. Lisboa, Portugal: Laboratório Nacional de Engenharia Civil (LNEC).
- Azeredo Lopes, S., & Cardoso, J. L. (2009). *Modelos de estimativa de frequência de acidentes e vítimas para dados bidirecionadas de auto-estradas Portuguesas – Uma abordagem Bayesiana*. Lisboa, Portugal: Laboratório Nacional de Engenharia Civil.
- Cafiso, S., D'Agostino, C., & Persaud, B. (2018). Investigating the influence of segmentation in estimating safety performance functions for roadway sections. *Journal of Traffic and Transportation Engineering*, 5(2), 129-136.
- Caliendo, C., Guida, M., & Parisi, A. (2007). A crash-prediction model for multilane roads. *Accident Analysis & Prevention*.
- Cardoso, L. J., & Gomes, S. V. (2002). Medidas de engenharia de baixo custo para melhoria da segurança rodoviária na rede rodoviária nacional. *2º Congresso Rodoviário Português*. Lisboa.
- Chang, L.-Y., & Chen, W.-C. (2005). Data mining of tree-based models to analyze freeway accident frequency. *Journal of Safety Research*, 36(4), 365-375.
- Costa, J. O., Jacques, M. A., Pereira, P. A., Freitas, E. F., & Soares, F. E. (2018). Portuguese two-lane highways: modelling crash frequencies for different temporal and spatial aggregation of crash data. *Transport*, 3(1), 92-103.
- Dong, X., Xie, K., & Yang, H. (2022). How did COVID-19 impact driving behaviors and crash Severity? A multigroup structural equation modeling. *Accident Analysis and Prevention*, 172.
- Eenink, R., Reurings, M., Elvik, R., Cardoso, J., & Wichert, S. (2005). *Accident Prediction Models and Road Safety Impact Assessment: recommendations for using these tools*. RIPCORD-ISEREST. 6TH EUROPEAN UNION FRAMEWORK PROGRAMME.
- Elvik, R., Høye, A., Vaa, T., & Sørensen, M. (2009). *The Handbook of Road Safety Measures* (Vol. 2).
- European Commission, Directorate-General for Mobility and Transport. (2020). *Next steps towards 'Vision Zero': EU road safety policy framework 2021-2030*. Luxemburgo: Publications Office.

- European Transport Safety Council ETSC. (2021). *RANKING EU PROGRESS ON ROAD SAFETY: 15th Road safety performance index report*. Bruxelas.
- Ferreira, S. M. (2010). *A segurança rodoviária no processo de planeamento de redes de transporte em meio urbano*. Porto, Portugal: Dissertação de doutoramento, Faculdade de Engenharia da Universidade do Porto, Laboratório Nacional de Engenharia Civil.
- Ferreira, S., Amorim, M., Lobo, A., Kern, M., Fanderl, N., & Couto, A. (2022). Travel mode preferences among German commuters over the course of COVID-19 pandemic. *Transport Policy*, 126, 55-64.
- Fridstrøm, L. (2015). *Disaggregate accident frequency and risk modelling. A Rough Guide*. Institute of Transport Economics (TØI), Oslo, Noruega.
- Fridstrøm, L., Ifver, J., Ingebrigtsen, S., Kulmala, R., & Thomsen, L. K. (1995). Measuring the contribution of randomness, exposure, weather, and daylight to the variation in road accident counts. *Accident Analysis & Prevention*.
- Gebregziabher, M., Hardin, J. W., Payne, E. H., Ramakrishnan, V., & Egede, L. E. (2018). An empirical approach to determine a threshold for assessing. 47(6), 1722-1378.
- Geedipally, S. R., Lord, D., & Park, B.-J. (2009). Analyzing Different Parameterizations of the Varying Dispersion Parameter as a Function of Segment Length. *Transportation Research Record*, 2103(1), 108-118.
- Gelman, A., Carlin, J., Stern, H., Rubin, D., Dunson, D., & Vehtari, A. (2021). *Bayesian Data Analysis Third edition (with errors fixed as of 15 February 2021)*. Chapman and Hall.
- Geyer, J., Lankina, E., Chan, C.-Y., Ragland, D., Pham, T., & Sharafsaleh, A. (2008). *Methods for Identifying High Collision Concentration Locations for Potential Safety Improvements*. Institute of Transportation Studies. Berkeley, USA: University of California, Berkeley.
- Glennon, J. C. (1987). *Effect of Alignment on Highway Safety*.
- Gomes, S. V. (2021). The influence of the infrastructure characteristics in urban road accidents occurrence. *Procedia - Social and Behavioral Sciences* 48, 1611-1621.
- Gomes, S. V., Cardoso, J. L., Roque, C., & Macedo, A. L. (2019). *Documento normativo para aplicação a arruamentos urbanos: fundamentos sobre utentes e rede rodoviária*. LNEC Departamento de Transportes, Lisboa.
- Green, E. R. (2018). *Segmentation Strategies for Road Safety Analysis*. Dissertação de Doutoramento, College of Engineering at the University of Kentucky, Lexington, USA.
- Greene, W. H. (2008). *Econometric Analysis 6th Edition*. New Jersey: Pearson International Edition.
- Guimarães, R. C., & Cabral, J. S. (1997). *Estatística*. Lisboa, Portugal.
- Hauer, E. (2004). Statistical Road Safety Modeling. *Transportation Research Record* 1897.
- Hauer, E., & Bamfo, J. (1997). *Two tools for finding what function links the dependent variable to the explanatory variables*.
- Islam, M. R., Abdel-Aty, M., Islam, Z., & Zhang, S. (2022). Risk-Compensation Trends in Road Safety during COVID-19. *Sustainability*, 14.

- Katrakazas, C., Michelaraki, E., Sekadakis, M., Ziakopoulos, A., Kontaxi, A., & Yannis, G. (2021). Identifying the impact of the COVID-19 pandemic on driving behavior using naturalistic driving data and time series forecasting. *Journey of Safety Research*, 78, 189-202.
- Khodadadi, A., Tsapakis, I., Shirazi, M., Das, S., & Lord, D. (2022). Derivation of the Empirical Bayesian method for the Negative Binomial-Lindley generalized linear model with application in traffic safety. *Accident Analysis & Prevention*.
- Koorey, G. (2009). Road Data Aggregation and Sectioning Considerations for Crash Analysis. *Transportation Research Record Journal of the Transportation Research Board*.
- Kronprasert, N., Boontan, K., & Kanha, P. (2021). Crash Prediction Models for Horizontal Curve Segments on Two-Lane Rural Roads in Thailand. *Sustainability* 13.
- Li, J. Q., & Yu, W. (2021). Enhanced Safety Performance Function for Highway Segments in Oklahoma. *Journal of Infrastructure Systems*, 27(3).
- Lopetrone, E., & Biondi, F. N. (2022). On the Effect of COVID-19 on Drivers' Behavior: A Survey Study. *Transportation Research Record*, 1-9.
- Lord, D., & Mannering, F. (2010). The Statistical Analysis of Crash-Frequency Data: *Transportation Research Part A: Policy and Practice*, Volume 44, 291-305.
- Lord, D., & Park, P. Y.-J. (2008). Investigating the effects of the fixed and varying dispersion parameters of Poisson-gamma models on empirical Bayes estimates. *Accident Analysis & Prevention*, Volume 4, 1441-1457.
- Mannering, F. L., & Bhat, C. R. (2014). Analytic methods in accident research: Methodological frontier and future directions. *Analytic methods in accident research*, 1, 1-22.
- McCullagh, P., & Nelder, J. A. (1989). *Generalized Linear Models*, 2nd Edition. Chapman and Hall.
- Milton, J., & Mannering, F. (1998). The relationship among highway geometrics, traffic-related. *Transportation* 25, 395-413.
- Muley, D., Shahin, M., Dias, C., & Abdullah, M. (2020). Role of Transport during Outbreak of Infectious Diseases: Evidence from the Past. *Sustainability*, 12(18).
- Naderan, A., & Babaei, M. (2011). Assessment of Statistical Models for Aggregate Crash Prediction.
- Organisation for Economic Co-operation and Development OECD/International Transport Forum ITF. (2008). *TOWARDS ZERO: Ambitious Road Safety Targets and the Safe System Approach*. Paris.
- Pedro, M., Lobo, A., Couto, A., & Rodrigo, C. M. (2012). Road Cross-Section Width and Free-Flow Speed on Two-Lane Rural Highways.
- Peltola, H., Rajamäki, R., & Luoma, J. (2013). A tool for safety evaluations of road improvements. *Accident Analysis & Prevention*, Volume 60, 277-288.
- Prevedouros, P. D., & Papacostas, C. S. (2009). *Transportation Engineering and Planning*, Third Edition. New Jersey, USA: Pearson Education.
- Rashidi, M. H., Keshavarz, S., Pazari, P., Safahieh, N., & Samimi, A. (2022). Modeling the accuracy of traffic crash prediction models. *IATSS Research*.
- Ribeiro, J. C. (2021). *Aplicação de Modelos de Previsão de Acidentes Rodoviários à Rede Ascendi*. Porto, Portugal: Dissertação de Mestrado em Engenharia Civil, Faculdade de Engenharia da Universidade do Porto.

- Roque, C., & Cardoso, J. L. (2014). Investigating the relationship between run-off-the-road crash. *Accident Analysis and Prevention* 63, 121-132.
- Saito, M., Brimley, B. K., & Schultz, G. G. (2011). *Calibration of the Highway Safety Manual and Development of New Safety Performance Functions*. Provo, UT: Brigham Young University Department of Civil & Environmental Eng.
- Silva, C. M., Bravo, J. M., & Gonçalves, J. (2021). *Impacto Económico e Social da Sinistralidade Rodoviária em Portugal*. Lisboa: CEGE - Centro de Estudos de Gestão do ISEG e Autoridade Nacional de Segurança Rodoviária (ANSR).
- Silva, P. B. (2019). *Modelos de previsão de acidentes em rodovia brasileira de pista dupla*. Tese de Doutorado em Transportes, Universidade de Brasília, Brasília, Brasil.
- Silva, P. B., Andrade, M., & Ferreira, S. (2021). Influence of segment length on the fitness of multivariate crash prediction models applied to a Brazilian multilane highway. *IATSS Research*, 45(4), 493-502.
- Souza, S. S. (2021). *Identificação e análise de fatores de risco em Autoestrada: aplicação de modelos estatísticos*. Dissertação de Mestrado em Engenharia Civil, Faculdade de Engenharia da Universidade do Porto, Porto, Portugal.
- Srinivasan, R., Carter, D., & Bauer, K. (2013). *Safety Performance Function Decision Guide: SPF Calibration vs SPF*. Washington D.C.: Federal Highway Administration Office of Safety FHWA.
- SWOV. (2012). The relation between speed and crashes. *SWOV Fact Sheet*.
- Tegge, R. A., Jo, J.-H., & Ouyang, Y. (2010). *Development and Application of Safety Performance Functions for Illinois*.
- Torre, F. L., Domenichini, L., Meocci, M., Graham, D., Karathodorou, N., Richter, T., . . . Laiou, A. (2016). Development of a Transnational Accident Prediction Model. *Transportation Research Procedia, Volume 4*, 1772-1781.
- Washington, S. P., Karlaftis, M. G., & Mannering, F. L. (2003). *Statistical and econometric methods for transportation data analysis, 2nd Edition*. Chapman & Hall/CRC.
- Wegman, F. (2021). Sustainable Safety: The Dutch Example of a Safe System Approach.
- Wegman, F., & Aarts, L. (2006). *Advancing Sustainable Safety*. SWOV Institute for Road Safety Research.
- World Health Organization WHO. (2021). *Global Plan: Decade of Action for Road Safety 2021-2030*. Genebra.
- Yannis, G., Dragomanovits, A., Laiou, A., Richter, T., Ruhl, S., Torre, F. L., . . . Li, H. (2016). Use of Accident Prediction Models in Road Safety Management – An International Inquiry. *Transportation Research Procedia, Volume 14*, 4257-4266.
- Yu, R., & Abdel-Aty, M. (2013). Multi-level Bayesian analyses for single- and multi-vehicle freeway crashes. *Accident Analysis and Prevention*, 58, 97-105.
- Zhang, Y., Xie, Y., & Li, L. (2012). Crash frequency analysis of different types of urban roadway segments using generalized additive model. *Journal of Safety Research, Volume 43*, 107-114.

Vision Zero challenge (<https://visionzerochallenge.org/vision-zero>). Acessado em 14/05/2022.

UCLA: Statistical Consulting Group (<https://stats.oarc.ucla.edu/spss/output/poisson-regression/>). Acessado em 10/06/2022.

ANEXO A

TMDA [VEÍCULOS/DIA] E PERCENTAGEM DE PESADOS NA BLA (2015 A 2021)

Sublanço	Sentido	Categoria Veículos	2015	2016	2017	2018	2019	2020	2021
Carvoeiro - Talhadas	C	Ligeiros + Pesados	5708	6090	6338	6523	6722	5315	5928
		% Pesados	19%	16%	16%	17%	17%	20%	19%
	D	Ligeiros + Pesados	5507	6086	6333	6533	6728	5298	5937
		% Pesados	17%	16%	16%	16%	17%	20%	19%
Talhadas - Reigoso	C	Ligeiros + Pesados	6583	6923	7195	7409	7630	6091	6809
		% Pesados	18%	18%	18%	18%	18%	19%	20%
	D	Ligeiros + Pesados	6508	6841	7107	7319	7536	6042	6758
		% Pesados	18%	17%	17%	17%	17%	18%	19%
Reigoso - Cambarinho	C	Ligeiros + Pesados	6155	6222	6464	6658	6861	5419	6067
		% Pesados	19%	16%	16%	17%	17%	20%	19%
	D	Ligeiros + Pesados	5942	6208	6448	6643	6866	5401	6061
		% Pesados	14%	16%	16%	16%	17%	20%	19%
Cambarinho - Vouzela Poente	C	Ligeiros + Pesados	6094	6209	6436	6579	6968	5523	5638
		% Pesados	20%	19%	19%	15%	16%	20%	19%
	D	Ligeiros + Pesados	6051	6197	6446	6492	6880	5404	5921
		% Pesados	19%	19%	18%	18%	18%	20%	19%
Vouzela Poente - Vouzela Nascente	C	Ligeiros + Pesados	6242	6454	6705	6909	7282	5718	6322
		% Pesados	19%	19%	19%	19%	19%	20%	21%
	D	Ligeiros + Pesados	6197	6408	6654	6854	7226	5668	6275
		% Pesados	18%	18%	18%	18%	17%	18%	19%
Vouzela Nascente - Ventosa	C	Ligeiros + Pesados	4084	4247	4400	4632	4856	3760	4342
		% Pesados	20%	16%	17%	17%	18%	20%	19%
	D	Ligeiros + Pesados	4201	4390	4581	4798	5044	3915	4535
		% Pesados	20%	16%	17%	17%	17%	20%	19%
Ventosa - Boa Aldeia Poente	C	Ligeiros + Pesados	4156	4295	4456	4588	4962	3900	4472
		% Pesados	20%	20%	20%	20%	19%	21%	20%
	D	Ligeiros + Pesados	4301	4454	4649	4766	5176	4076	4611
		% Pesados	20%	20%	20%	18%	20%	21%	20%
Boa Aldeia Poente - Boa Aldeia Nascente	C	Ligeiros + Pesados	3354	3529	3685	3821	4061	3178	3633
		% Pesados	17%	17%	17%	17%	17%	19%	19%
	D	Ligeiros + Pesados	3364	3540	3698	3831	4076	3159	3625
		% Pesados	18%	18%	17%	17%	17%	19%	19%
EN2 - Caçador	C	Ligeiros + Pesados	5009	5403	5712	5960	6185	4839	5682
		% Pesados	22%	21%	21%	21%	21%	21%	21%
	D	Ligeiros + Pesados	4751	5133	5429	5667	5880	4629	5457
		% Pesados	20%	20%	20%	20%	20%	19%	19%
Caçador - Fagilde	C	Ligeiros + Pesados	6016	6450	6785	7079	7345	5816	6664
		% Pesados	15%	14%	14%	14%	15%	17%	16%
	D	Ligeiros + Pesados	6000	6434	6767	7075	7338	5766	6615
		% Pesados	14%	13%	14%	14%	14%	16%	16%
	C	Ligeiros + Pesados	6758	7022	7292	7534	7994	6205	6914

Fagilde - Mangualde	D	% Pesados	14%	12%	13%	13%	13%	15%	15%
		Ligeiros + Pesados	6747	6965	7158	7040	7216	5777	6907
Mangualde - Chãs de Tavares	C	% Pesados	14%	12%	13%	12%	13%	15%	15%
		Ligeiros + Pesados	4067	4373	4624	4734	4861	3798	4452
	D	% Pesados	23%	24%	25%	24%	25%	29%	28%
		Ligeiros + Pesados	3991	4277	4535	4659	4760	3687	4328
Chãs de Tavares - Fornos de Algodres	C	% Pesados	22%	23%	23%	23%	23%	27%	25%
		Ligeiros + Pesados	3881	4177	4416	4523	4622	3611	4229
	D	% Pesados	24%	23%	23%	23%	23%	26%	27%
		Ligeiros + Pesados	3792	4080	4313	4414	4510	3496	4123
Fornos de Algodres - Celorico	C	% Pesados	23%	23%	23%	23%	23%	25%	26%
		Ligeiros + Pesados	3672	3950	4172	4279	4380	3404	3994
	D	% Pesados	23%	26%	26%	26%	27%	31%	30%
		Ligeiros + Pesados	3595	3864	4093	4193	4281	3288	3876
Celorico - EN17	C	% Pesados	24%	24%	25%	24%	25%	29%	27%
		Ligeiros + Pesados	4008	4198	4425	4528	4628	3644	4268
	D	% Pesados	25%	24%	24%	24%	24%	29%	29%
		Ligeiros + Pesados	3816	3991	4206	4307	4403	3459	4069
EN17 - Ratoeira Poente	C	% Pesados	18%	16%	16%	16%	16%	20%	21%
		Ligeiros + Pesados	4200	4219	4434	4541	4667	3647	4249
	D	% Pesados	31%	26%	26%	26%	27%	31%	29%
		Ligeiros + Pesados	3938	4102	4320	4430	4537	3496	4103
IP2/A25 - Guarda	C	% Pesados	18%	24%	25%	24%	25%	29%	27%
		Ligeiros + Pesados	5734	3630	3837	3969	4128	3211	3859
	D	% Pesados	21%	23%	23%	23%	24%	29%	27%
		Ligeiros + Pesados	3793	4027	4287	4447	4596	3569	4226
Guarda - Pinhel	C	% Pesados	27%	24%	24%	24%	24%	28%	26%
		Ligeiros + Pesados	4392	4186	4405	4520	4628	3505	4155
	D	% Pesados	29%	29%	29%	29%	29%	31%	31%
		Ligeiros + Pesados	3497	3334	3511	3607	3704	2950	3579
Pinhel - Pínzio	C	% Pesados	18%	18%	18%	18%	18%	20%	21%
		Ligeiros + Pesados	2993	3285	3427	3490	3558	2682	3212
	D	% Pesados	36%	33%	34%	34%	35%	42%	39%
		Ligeiros + Pesados	3020	3267	3420	3483	3534	2613	3168
Pínzio - Alto de Leomil	C	% Pesados	35%	32%	32%	32%	33%	41%	37%
		Ligeiros + Pesados	3324	3576	3728	3784	3837	2793	3324
	D	% Pesados	34%	34%	34%	34%	34%	39%	40%
		Ligeiros + Pesados	3303	3559	3706	3761	3813	2712	3255
Alto de Leomil - Vilar Formoso	C	% Pesados	35%	36%	35%	36%	35%	38%	38%
		Ligeiros + Pesados	2826	2993	3094	3135	3173	2371	2813
	D	Ligeiros + Pesados	2844	2960	3086	3128	3151	2303	2799

		% Pesados	40%	35%	36%	36%	37%	46%	42%
Ratoeira Poente - Ratoeira Nascente	C	Ligeiros + Pesados	4722	4360	4582	4692	4808	3727	4337
		% Pesados	25%	25%	25%	25%	25%	28%	28%
	D	Ligeiros + Pesados	4418	4089	4296	4396	4504	3408	3974
		% Pesados	27%	27%	26%	26%	26%	29%	29%
Boa Aldeia Nascente - Fail (A24/A25)	C	Ligeiros + Pesados	3358	3581	3759	3942	4133	3169	3644
		% Pesados	17%	15%	16%	16%	17%	19%	19%
	D	Ligeiros + Pesados	3366	3572	3752	3938	4109	3145	3646
		% Pesados	17%	14%	15%	15%	16%	19%	18%
Ratoeira Nascente - IP2/A25	C	Ligeiros + Pesados	5734	3801	4026	4167	4317	3400	4051
		% Pesados	21%	22%	22%	22%	22%	25%	26%
	D	Ligeiros + Pesados	3793	3859	4093	4233	4379	3427	4093
		% Pesados	27%	24%	24%	24%	24%	26%	27%
IC2 (EN1) - Carvoeiro	C	Ligeiros + Pesados	7114	7545	7915	8172	8449	6754	7667
		% Pesados	17%	17%	17%	17%	17%	18%	19%
	D	Ligeiros + Pesados	7381	7831	8215	8482	8772	6980	7932
		% Pesados	17%	17%	17%	17%	17%	18%	18%

ANEXO B

MATRIZ DE CORRELAÇÃO ENTRE AS VARIÁVEIS INDEPENDENTES

ANEXO B.1 – MATRIZ DE CORRELAÇÃO PARA AS VARIÁVEIS EXPLICATIVAS DOS ACIDENTES TOTAIS

	Velocidade	Radar	Sentido	Raio	Larg_Sep_Cent	Larg_Bext	N_Vias	Outras_Vias	Ano	LN_Compr	LN_TMDA	LN_% _Pesados
Velocidade	1											
Radar	-0,081	1										
Sentido	-0,246	0,054	1									
Raio	-0,052	0,065	0,002	1								
Larg_Sep_Cent	-0,069	0,009	0,001	0,011	1							
Larg_Bext	-0,132	0,035	0,123	0,012	0,017	1						
N_Vias	0,050	0,006	-0,030	0,032	-0,088	0,058	1					
Outras_Vias	-0,088	0,040	0,054	0,070	0,086	0,786	0,054	1				
Ano	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	1			
LN_Compr	0,039	0,090	-0,001	0,202	-0,079	0,074	0,015	0,198	0,000	1		
LN_TMDA	-0,033	0,061	-0,020	0,048	0,119	0,006	0,092	-0,036	0,036	-0,152	1	
LN_%_Pesados	-0,014	0,044	-0,076	0,047	0,151	-0,020	0,115	0,067	0,162	0,105	-0,821	1

ANEXO B.2 – MATRIZ DE CORRELAÇÃO PARA AS VARIÁVEIS EXPLICATIVAS DOS ACIDENTES COM VÍTIMAS

	Velocidade	Radar	Sentido	Raio	Larg_Sep_Cent	Larg_Bext	N_Vias	Outras_Vias	Ano	LN_Compr	LN_TMDA	LN_%_Pesados
Velocidade	1											
Radar	-0,056	1										
Sentido	-0,251	0,054	1									
Raio	-0,057	0,065	0,002	1								
Larg_Sep_Cent	-0,085	0,009	0,001	0,011	1							
Larg_Bext	-0,129	0,035	0,123	0,012	0,017	1						
N_Vias	0,051	0,006	-0,030	0,032	-0,088	0,058	1					
Outras_Vias	-0,088	0,040	0,054	0,070	0,086	0,786	0,054	1				
Ano	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	1			
LN_Compr	0,046	0,090	-0,001	0,202	-0,079	0,074	0,015	0,198	0,000	1		
LN_TMDA	-0,034	0,061	-0,020	0,048	0,119	0,006	0,092	-0,036	0,036	-0,152	1	
LN_%_Pesados	-0,013	0,044	-0,076	0,047	0,151	-0,020	0,115	0,067	0,162	0,105	-0,821	1

ANEXO C

RESULTADOS DA MODELAGEM NO SOFTWARE SPSS

ANEXO C.1 – MODELO DE FREQUÊNCIA DE ACIDENTES TOTAIS (2015-2021)**Distribuição Poisson**

Goodness of Fit^a			
	Value	df	Value/df
Deviance	3465.390	6366	.544
Scaled Deviance	3465.390	6366	
Pearson Chi-Square	7736.036	6366	1.215
Scaled Pearson Chi-Square	7736.036	6366	
Log Likelihood ^b	-2534.269		
Akaike's Information Criterion (AIC)	5090.538		
Finite Sample Corrected AIC (AICC)	5090.579		
Bayesian Information Criterion (BIC)	5164.903		
Consistent AIC (CAIC)	5175.903		

Dependent Variable: Nº de Acidentes Totais

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade^a

a. Information criteria are in smaller-is-better form.

b. The full log likelihood function is displayed and used in computing information criteria.

Omnibus Test^a		
Likelihood Ratio Chi-Square	df	Sig.
676.831	10	.000

Dependent Variable: Nº de Acidentes Totais

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade^a

a. Compares the fitted model against the intercept-only model.

Tests of Model Effects			
Source	Type III		
	Wald Chi-Square	df	Sig.
(Intercept)	323.088	1	.000
LN_TMDA	178.790	1	.000
LN_Comprimento	394.762	1	.000
Raio_Curva_Circular	35.944	2	<.001
Outras_Vias	23.590	3	<.001
Larg_Sep_Central	10.382	1	.001
Velocidade	8.298	2	.016

Dependent Variable: Nº de Acidentes Totais

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade

Parameter Estimates					
Parameter	B	Std. Error	95% Wald Confidence Interval		Hypothesis Test
			Lower	Upper	Wald Chi-Square
(Intercept)	-21.830	1.2108	-24.204	-19.457	325.047
LN_TMDA	1.709	.1278	1.459	1.960	178.790
LN_Comprimento	.900	.0453	.811	.989	394.762
[Raio_Curva_Circular=1]	.193	.0964	.004	.382	3.995
[Raio_Curva_Circular=2]	.613	.1102	.397	.829	30.957
[Raio_Curva_Circular=3]	0 ^a	.	.	.	.
[Outras_Vias=1]	-.653	.1603	-.967	-.339	16.582
[Outras_Vias=2]	-.011	.0779	-.164	.142	.020
[Outras_Vias=3]	-.860	.3066	-1.461	-.259	7.873
[Outras_Vias=4]	0 ^a	.	.	.	.
[Larg_Sep_Central=0]	.220	.0682	.086	.353	10.382
[Larg_Sep_Central=1]	0 ^a	.	.	.	.
[Velocidade=1]	-2.097	1.0022	-4.061	-.132	4.376
[Velocidade=2]	-.150	.0740	-.295	-.005	4.110
[Velocidade=3]	0 ^a	.	.	.	.
(Scale)	1 ^b				

Parameter Estimates					
Parameter	Hypothesis Test		Exp(B)	95% Wald Confidence Interval for Exp(B)	
	df	Sig.		Lower	Upper
(Intercept)	1	.000	<.001	3.080E-11	3.547E-9
LN_TMDA	1	.000	5.524	4.300	7.097
LN_Comprimento	1	.000	2.459	2.250	2.688
[Raio_Curva_Circular=1]	1	.046	1.212	1.004	1.465
[Raio_Curva_Circular=2]	1	<.001	1.847	1.488	2.292
[Raio_Curva_Circular=3]	.	.	1	.	.
[Outras_Vias=1]	1	<.001	.521	.380	.713
[Outras_Vias=2]	1	.888	.989	.849	1.152
[Outras_Vias=3]	1	.005	.423	.232	.772
[Outras_Vias=4]	.	.	1	.	.
[Larg_Sep_Central=0]	1	.001	1.246	1.090	1.424
[Larg_Sep_Central=1]	.	.	1	.	.
[Velocidade=1]	1	.036	.123	.017	.876
[Velocidade=2]	1	.043	.861	.745	.995
[Velocidade=3]	.	.	1	.	.
(Scale)					

Dependent Variable: N° de Acidentes Totais

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade

a. Set to zero because this parameter is redundant.

b. Fixed at the displayed value.

Distribuição Binomial Negativa

Warnings
All convergence criteria are satisfied, but the Hessian matrix is singular.
The GENLIN procedure continues despite the above warning(s). Subsequent results shown are based on the last iteration. Validity of the model fit is uncertain.

Goodness of Fit ^a			
	Value	df	Value/df
Deviance	3345.937	6365	.526
Scaled Deviance	3345.937	6365	
Pearson Chi-Square	7593.823	6365	1.193
Scaled Pearson Chi-Square	7593.823	6365	
Log Likelihood ^b	-2523.911		
Akaike's Information Criterion (AIC)	5071.823		
Finite Sample Corrected AIC (AICC)	5071.872		
Bayesian Information Criterion (BIC)	5152.948		
Consistent AIC (CAIC)	5164.948		

Dependent Variable: N° de Acidentes Totais

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade^a

a. Information criteria are in smaller-is-better form.

b. The full log likelihood function is displayed and used in computing information criteria.

Omnibus Test ^a		
Likelihood Ratio Chi-Square	df	Sig.
487.568	10	.000

Dependent Variable: N° de Acidentes Totais

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade^a

a. Compares the fitted model against the intercept-only model.

Tests of Model Effects

Source	Type III		
	Wald Chi-Square	df	Sig.
(Intercept)	313.780	1	.000
LN_TMDA	173.450	1	.000
LN Comprimento	377.181	1	.000
Raio_Curva_Circular	34.630	2	<.001
Outras_Vias	23.354	3	<.001
Larg_Sep_Central	9.648	1	.002
Velocidade	7.956	2	.019

Dependent Variable: Nº de Acidentes Totais

Model: (Intercept), LN_TMDA, LN Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade

Parameter Estimates					
Parameter	B	Std. Error	95% Wald Confidence Interval		Hypothesis Test
			Lower	Upper	Wald Chi-Square
(Intercept)	-21.774	1.2263	-24.177	-19.370	315.278
LN_TMDA	1.706	.1295	1.452	1.959	173.450
LN Comprimento	.896	.0461	.805	.986	377.181
[Raio_Curva_Circular=1]	.192	.0973	.002	.383	3.909
[Raio_Curva_Circular=2]	.611	.1116	.392	.830	29.982
[Raio_Curva_Circular=3]	0 ^a	.	.	.	.
[Outras_Vias=1]	-.653	.1612	-.969	-.337	16.398
[Outras_Vias=2]	-.009	.0791	-.164	.146	.012
[Outras_Vias=3]	-.859	.3080	-1.462	-.255	7.774
[Outras_Vias=4]	0 ^a	.	.	.	.
[Larg_Sep_Central=0]	.215	.0693	.079	.351	9.648
[Larg_Sep_Central=1]	0 ^a	.	.	.	.
[Velocidade=1]	-2.092	1.0042	-4.060	-.124	4.340
[Velocidade=2]	-.146	.0750	-.293	.001	3.799
[Velocidade=3]	0 ^a	.	.	.	.
(Scale)	1 ^b				
(Negative binomial)	.113 ^c	.	.	.	
Parameter Estimates					
Parameter	Hypothesis Test		Exp(B)	95% Wald Confidence Interval for Exp(B)	
	df	Sig.		Lower	Upper
(Intercept)	1	.000	<.001	3.162E-11	3.869E-9
LN_TMDA	1	.000	5.504	4.271	7.095
LN Comprimento	1	.000	2.449	2.237	2.680
[Raio_Curva_Circular=1]	1	.048	1.212	1.002	1.467
[Raio_Curva_Circular=2]	1	<.001	1.842	1.480	2.292

[Raio_Curva_Circular=3]	.	.	1	.	.
[Outras_Vias=1]	1	<.001	.521	.380	.714
[Outras_Vias=2]	1	.912	.991	.849	1.158
[Outras_Vias=3]	1	.005	.424	.232	.775
[Outras_Vias=4]	.	.	1	.	.
[Larg_Sep_Central=0]	1	.002	1.240	1.083	1.420
[Larg_Sep_Central=1]	.	.	1	.	.
[Velocidade=1]	1	.037	.123	.017	.884
[Velocidade=2]	1	.051	.864	.746	1.001
[Velocidade=3]	.	.	1	.	.
(Scale)					
(Negative binomial)					

Dependent Variable: Nº de Acidentes Totais

Model: (Intercept), LN_TMADA, LN_Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade

- Set to zero because this parameter is redundant.
- Fixed at the displayed value.
- Hessian matrix singularity is caused by the scale or negative binomial parameter.

ANEXO C.2. – MODELO DE FREQUÊNCIA DE ACIDENTES COM VÍTIMAS (2015-2021)

Distribuição Poisson

Goodness of Fit ^a			
	Value	df	Value/df
Deviance	1738.852	6370	.273
Scaled Deviance	1738.852	6370	
Pearson Chi-Square	7434.038	6370	1.167
Scaled Pearson Chi-Square	7434.038	6370	
Log Likelihood ^b	-1152.517		
Akaike's Information Criterion (AIC)	2319.033		
Finite Sample Corrected AIC (AICC)	2319.051		
Bayesian Information Criterion (BIC)	2366.356		
Consistent AIC (CAIC)	2373.356		

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Velocidade, Sentido^a

a. Information criteria are in smaller-is-better form.

b. The full log likelihood function is displayed and used in computing information criteria.

Omnibus Test ^a		
Likelihood Ratio Chi-Square	df	Sig.
256.135	6	.000

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Velocidade, Sentido^a

a. Compares the fitted model against the intercept-only model.

Tests of Model Effects			
Source	Type III		
	Wald Chi-Square	df	Sig.
(Intercept)	128.831	1	.000
LN_TMDA	61.654	1	<.001
LN_Comprimento	204.240	1	.000
Raio_Curva_Circular	20.878	2	<.001
Velocidade	5.353	1	.021
Sentido	7.234	1	.007

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Velocidade, Sentido

Parameter Estimates					
Parameter	B	Std. Error	95% Wald Confidence Interval		Hypothesis Test
			Lower	Upper	Wald Chi-Square
(Intercept)	-23.877	2.1009	-27.995	-19.760	129.165
LN_TMDA	1.743	.2220	1.308	2.178	61.654
LN_Comprimento	1.068	.0748	.922	1.215	204.240
[Raio_Curva_Circular=1]	-.036	.1639	-.357	.286	.047
[Raio_Curva_Circular=2]	.614	.1851	.251	.977	10.997
[Raio_Curva_Circular=3]	0 ^a	.	.	.	.
[Velocidade=0]	-.298	.1288	-.550	-.046	5.353
[Velocidade=1]	0 ^a	.	.	.	.
[Sentido=0]	-.311	.1157	-.538	-.084	7.234
[Sentido=1]	0 ^a	.	.	.	.
(Scale)	1 ^b				

Parameter Estimates					
Parameter	Hypothesis Test		Exp(B)	95% Wald Confidence Interval for Exp(B)	
	df	Sig.		Lower	Upper
(Intercept)	1	.000	<.001	6.949E-13	2.622E-9
LN_TMDA	1	<.001	5.714	3.698	8.828
LN_Comprimento	1	.000	2.911	2.514	3.370
[Raio_Curva_Circular=1]	1	.828	.965	.700	1.331
[Raio_Curva_Circular=2]	1	<.001	1.848	1.285	2.656
[Raio_Curva_Circular=3]	.	.	1	.	.
[Velocidade=0]	1	.021	.742	.577	.955
[Velocidade=1]	.	.	1	.	.
[Sentido=0]	1	.007	.733	.584	.919
[Sentido=1]	.	.	1	.	.
(Scale)					

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Velocidade, Sentido

a. Set to zero because this parameter is redundant.

b. Fixed at the displayed value.

Distribuição Binomial Negativa

Goodness of Fit ^a			
	Value	df	Value/df
Deviance	1357.762	6369	.213
Scaled Deviance	1357.762	6369	
Pearson Chi-Square	6781.104	6369	1.065
Scaled Pearson Chi-Square	6781.104	6369	
Log Likelihood ^b	-1137.430		
Akaike's Information Criterion (AIC)	2290.860		
Finite Sample Corrected AIC (AICC)	2290.882		
Bayesian Information Criterion (BIC)	2344.943		
Consistent AIC (CAIC)	2352.943		

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Velocidade, Sentido^a

a. Information criteria are in smaller-is-better form.

b. The full log likelihood function is displayed and used in computing information criteria.

Omnibus Test ^a		
Likelihood Ratio Chi-Square	df	Sig.
240.917	6	.000

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Velocidade, Sentido^a

a. Compares the fitted model against the intercept-only model.

Tests of Model Effects			
Source	Type III		
	Wald Chi-Square	df	Sig.
(Intercept)	109.275	1	.000
LN_TMDA	51.412	1	<.001
LN_Comprimento	161.349	1	.000
Raio_Curva_Circular	17.492	2	<.001
Velocidade	4.218	1	.040
Sentido	6.861	1	.009

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Velocidade, Sentido

Parameter Estimates					
Parameter	B	Std. Error	95% Wald Confidence Interval		Hypothesis Test
			Lower	Upper	Wald Chi-Square
(Intercept)	-23.305	2.2275	-27.671	-18.939	109.462
LN_TMDSA	1.692	.2360	1.229	2.154	51.412
LN_Comprimento	1.044	.0822	.883	1.205	161.349
[Raio_Curva_Circular=1]	-.024	.1724	-.362	.314	.020
[Raio_Curva_Circular=2]	.618	.1978	.231	1.006	9.767
[Raio_Curva_Circular=3]	0 ^a	.	.	.	.
[Velocidade=0]	-.284	.1385	-.556	-.013	4.218
[Velocidade=1]	0 ^a	.	.	.	.
[Sentido=0]	-.329	.1257	-.576	-.083	6.861
[Sentido=1]	0 ^a	.	.	.	.
(Scale)	1 ^b				
(Negative binomial)	1.831	.5078	1.063	3.153	
Parameter Estimates					
Parameter	Hypothesis Test		Exp(B)	95% Wald Confidence Interval for Exp(B)	
	df	Sig.		Lower	Upper
(Intercept)	1	.000	<.001	9.607E-13	5.953E-9
LN_TMDSA	1	<.001	5.430	3.419	8.624
LN_Comprimento	1	.000	2.840	2.418	3.337
[Raio_Curva_Circular=1]	1	.888	.976	.696	1.368
[Raio_Curva_Circular=2]	1	.002	1.856	1.259	2.735
[Raio_Curva_Circular=3]	.	.	1	.	.
[Velocidade=0]	1	.040	.752	.574	.987
[Velocidade=1]	.	.	1	.	.
[Sentido=0]	1	.009	.719	.562	.920
[Sentido=1]	.	.	1	.	.
(Scale)					
(Negative binomial)					

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDSA, LN_Comprimento, Raio_Curva_Circular, Velocidade, Sentido

a. Set to zero because this parameter is redundant.

b. Fixed at the displayed value.

ANEXO C.3 – MODELO DE FREQUÊNCIA DE ACIDENTES TOTAIS (2015-2019)**Distribuição Poisson**

Goodness of Fit^a			
	Value	df	Value/df
Deviance	2593.295	4544	.571
Scaled Deviance	2593.295	4544	
Pearson Chi-Square	5720.614	4544	1.259
Scaled Pearson Chi-Square	5720.614	4544	
Log Likelihood ^b	-1904.515		
Akaike's Information Criterion (AIC)	3831.029		
Finite Sample Corrected AIC (AICC)	3831.088		
Bayesian Information Criterion (BIC)	3901.693		
Consistent AIC (CAIC)	3912.693		

Dependent Variable: Nº de Acidentes Totais

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade^a

a. Information criteria are in smaller-is-better form.

b. The full log likelihood function is displayed and used in computing information criteria.

Omnibus Test^a		
Likelihood Ratio Chi-Square	df	Sig.
485.498	10	.000

Dependent Variable: Nº de Acidentes Totais

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade^a

a. Compares the fitted model against the intercept-only model.

Tests of Model Effects			
Source	Type III		
	Wald Chi-Square	df	Sig.
(Intercept)	220.453	1	.000
LN_TMDA	118.844	1	.000
LN_Comprimento	281.140	1	.000
Raio_Curva_Circular	26.769	2	<.001
Outras_Vias	18.285	3	<.001
Larg_Sep_Central	15.682	1	<.001
Velocidade	5.007	2	.082

Dependent Variable: N° de Acidentes Totais

Model: (Intercept), LN_TMADA, LN_Comprimento, Raio_Curva_Circular,
Outras_Vias, Larg_Sep_Central, Velocidade

Parameter Estimates					
Parameter	B	Std. Error	95% Wald Confidence Interval		Hypothesis Test
			Lower	Upper	Wald Chi-Square
(Intercept)	-21.084	1.4176	-23.862	-18.305	221.196
LN_TMADA	1.632	.1497	1.339	1.925	118.844
LN_Comprimento	.870	.0519	.769	.972	281.140
[Raio_Curva_Circular=1]	.243	.1107	.026	.460	4.832
[Raio_Curva_Circular=2]	.632	.1272	.382	.881	24.653
[Raio_Curva_Circular=3]	0 ^a	.	.	.	.
[Outras_Vias=1]	-.616	.1799	-.968	-.263	11.724
[Outras_Vias=2]	.068	.0876	-.104	.240	.598
[Outras_Vias=3]	-.776	.3395	-1.441	-.110	5.222
[Outras_Vias=4]	0 ^a	.	.	.	.
[Larg_Sep_Central=0]	.308	.0777	.155	.460	15.682
[Larg_Sep_Central=1]	0 ^a	.	.	.	.
[Velocidade=1]	-1.833	1.0028	-3.798	.133	3.340
[Velocidade=2]	-.113	.0842	-.278	.052	1.793
[Velocidade=3]	0 ^a	.	.	.	.
(Scale)	1 ^b				

Parameter Estimates					
Parameter	Hypothesis Test		Exp(B)	95% Wald Confidence Interval for Exp(B)	
	df	Sig.		Lower	Upper
(Intercept)	1	.000	<.001	4.334E-11	1.122E-8
LN_TMADA	1	.000	5.114	3.813	6.857
LN_Comprimento	1	.000	2.388	2.157	2.644
[Raio_Curva_Circular=1]	1	.028	1.275	1.027	1.584
[Raio_Curva_Circular=2]	1	<.001	1.880	1.466	2.413
[Raio_Curva_Circular=3]	.	.	1	.	.
[Outras_Vias=1]	1	<.001	.540	.380	.768
[Outras_Vias=2]	1	.439	1.070	.901	1.271
[Outras_Vias=3]	1	.022	.460	.237	.896
[Outras_Vias=4]	.	.	1	.	.
[Larg_Sep_Central=0]	1	<.001	1.361	1.168	1.584
[Larg_Sep_Central=1]	.	.	1	.	.
[Velocidade=1]	1	.068	.160	.022	1.142
[Velocidade=2]	1	.181	.893	.757	1.054
[Velocidade=3]	.	.	1	.	.
(Scale)					

Dependent Variable: N° de Acidentes Totais

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular, Outras_Vias, Larg_Sep_Central, Velocidade

a. Set to zero because this parameter is redundant.

b. Fixed at the displayed value.

ANEXO C.4 – MODELO DE FREQUÊNCIA DE ACIDENTES COM VÍTIMAS (2015-2019)

Distribuição Binomial Negativa

Goodness of Fit ^a			
	Value	df	Value/df
Deviance	1027.357	4549	.226
Scaled Deviance	1027.357	4549	
Pearson Chi-Square	4826.651	4549	1.061
Scaled Pearson Chi-Square	4826.651	4549	
Log Likelihood ^b	-859.988		
Akaike's Information Criterion (AIC)	1731.977		
Finite Sample Corrected AIC (AICC)	1731.995		
Bayesian Information Criterion (BIC)	1770.521		
Consistent AIC (CAIC)	1776.521		

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular^a

a. Information criteria are in smaller-is-better form.

b. The full log likelihood function is displayed and used in computing information criteria.

Omnibus Test ^a		
Likelihood Ratio Chi-Square	df	Sig.
161.235	4	.000

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular^a

a. Compares the fitted model against the intercept-only model.

Tests of Model Effects			
Source	Type III		
	Wald Chi-Square	df	Sig.
(Intercept)	71.475	1	.000
LN_TMDA	32.335	1	<.001
LN_Comprimento	115.275	1	.000
Raio_Curva_Circular	12.361	2	.002

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMDA, LN_Comprimento, Raio_Curva_Circular

Parameter Estimates					
Parameter	B	Std. Error	95% Wald Confidence Interval		Hypothesis Test
			Lower	Upper	Wald Chi-Square
(Intercept)	-22.315	2.5923	-27.395	-17.234	74.097
LN_TMADA	1.563	.2748	1.024	2.101	32.335
LN_Comprimento	1.006	.0937	.822	1.189	115.275
[Raio_Curva_Circular=1]	.141	.2033	-.258	.539	.479
[Raio_Curva_Circular=2]	.704	.2320	.249	1.159	9.208
[Raio_Curva_Circular=3]	0 ^a	.	.	.	.
(Scale)	1 ^b				
(Negative binomial)	1.763	.5784	.927	3.353	
Parameter Estimates					
Parameter	Hypothesis Test		Exp(B)	95% Wald Confidence Interval for Exp(B)	
	df	Sig.		Lower	Upper
(Intercept)	1	.000	<.001	1.266E-12	3.277E-8
LN_TMADA	1	<.001	4.771	2.784	8.175
LN_Comprimento	1	.000	2.733	2.275	3.284
[Raio_Curva_Circular=1]	1	.489	1.151	.773	1.715
[Raio_Curva_Circular=2]	1	.002	2.022	1.283	3.186
[Raio_Curva_Circular=3]	.	.	1	.	.
(Scale)					
(Negative binomial)					

Dependent Variable: Nº de Acidentes com Vítimas

Model: (Intercept), LN_TMADA, LN_Comprimento, Raio_Curva_Circular

a. Set to zero because this parameter is redundant.


b. Fixed at the displayed value.

ANEXO D


COMPARAÇÃO ENTRE OS MODELOS COM DADOS DE 7 E DADOS DE 5 ANOS

D.1. ACIDENTES TOTAIS


D.1.1. RESÍDUOS ACUMULADOS ACIDENTES TOTAIS (2015-2019) PARA O TMDA – PREVISÃO DO MODELO 7 ANOS




D.1.2. RESÍDUOS ACUMULADOS ACIDENTES TOTAIS (2015-2019) PARA O COMPRIMENTO – PREVISÃO DO MODELO 7 ANOS



D.1.3. RESÍDUOS ACUMULADOS ACIDENTES TOTAIS (2015-2019) PARA O TMDA – PREVISÃO DO MODELO 5 ANOS




D.1.4. RESÍDUOS ACUMULADOS ACIDENTES TOTAIS (2015-2019) PARA O COMPRIMENTO – PREVISÃO DO MODELO 5 ANOS




D.2. ACIDENTES COM VÍTIMAS


D.2.1. RESÍDUOS ACUMULADOS ACIDENTES COM VÍTIMAS (2015-2019) PARA O TMDA – PREVISÃO DO MODELO 7 ANOS




D.2.2. RESÍDUOS ACUMULADOS ACIDENTES COM VÍTIMAS (2015-2019) PARA O COMPRIMENTO – PREVISÃO DO MODELO 7 ANOS



D.2.3 RESÍDUOS ACUMULADOS ACIDENTES COM VÍTIMAS (2015-2019) PARA O TMDA – PREVISÃO DO MODELO 5 ANOS



D.2.4. RESÍDUOS ACUMULADOS ACIDENTES COM VÍTIMAS (2015-2019) PARA O COMPRIMENTO – PREVISÃO DO MODELO 5 ANOS



ANEXO E

RESULTADOS DA APLICAÇÃO DO MODELO DE ACIDENTES TOTAIS

ANEXO E.1 – IDENTIFICAÇÃO DOS SUBLANÇOS DA A25 PARA MELHORIA DA SR. MEDIDA PROATIVA VS. REATIVA

Posição	Localização	Sentido	Previsão Acidentes Totais 2023	Média observada Acidentes Totais (2015-2021)	Posição no ranking da média observada Acidentes Totais (2015-2021)
1º	Carvoeiro - Talhadas	SC	10,3	6,3	3º
2º	Talhadas - Reigoso	SD	9,1	5,3	7º
3º	Carvoeiro - Talhadas	SD	8,9	14,0	1º
4º	Talhadas - Reigoso	SC	7,6	2,9	18º
5º	Caçador - Fagilde	SC	6,8	6,9	2º
6º	Caçador - Fagilde	SD	6,5	5,6	6º
7º	Fornos de Algodres - Celorico	SC	6,0	5,9	5º
8º	IP2/A25 - Guarda	SD	5,9	3,4	15º
9º	IP2/A25 - Guarda	SC	5,9	2,3	23º
10º	Mangualde - Chãs de Tavares	SC	5,8	2,0	29º
11º	Mangualde - Chãs de Tavares	SD	5,7	3,9	10º
12º	Cambarinho - Vouzela Poente	SC	5,7	3,0	17º
13º	Fornos de Algodres - Celorico	SD	5,1	2,3	22º
14º	Cambarinho - Vouzela Poente	SD	5,1	2,1	27º
15º	Reigoso - Cambarinho	SD	5,0	3,6	14º
16º	Reigoso - Cambarinho	SC	5,0	2,3	24º
17º	Fagilde - Mangualde	SD	4,8	6,1	4º
18º	Fagilde - Mangualde	SC	4,8	2,6	19º
19º	Vouzela Nascente - Ventosa	SD	4,7	1,3	36º
20º	Vouzela Nascente - Ventosa	SC	4,7	2,3	26º
21º	Chãs de Tavares - Fornos de Algodres	SC	4,2	1,4	33º
22º	Chãs de Tavares - Fornos de Algodres	SD	4,2	3,6	11º
23º	IC2 (EN1) - Carvoeiro	SC	4,1	3,6	13º
24º	Boa Aldeia Nascente - Fail (A24/A25)	SD	4,0	3,1	16º
25º	Pinhel - Pínzio	SC	3,9	4,9	8º
26º	Pinhel - Pínzio	SD	3,8	2,6	20º
27º	Boa Aldeia Nascente - Fail (A24/A25)	SC	3,8	3,9	9º
28º	Ventosa - Boa Aldeia Poente	SD	3,6	2,3	25º
29º	IC2 (EN1) - Carvoeiro	SD	3,5	2,0	28º
30º	Ventosa - Boa Aldeia Poente	SC	3,5	1,4	34º
31º	Alto de Leomil - Vilar Formoso	SD	2,8	2,3	21º

32º	Alto de Leomil - Vilar Formoso	SC	2,6	1,6	31º
33º	EN17 - Ratoeira Poente	SC	2,4	3,6	12º
34º	Pínzio - Alto de Leomil	SC	2,1	1,9	30º
35º	EN17 - Ratoeira Poente	SD	2,1	1,3	35º
36º	Vouzela Poente - Vouzela Nascente	SC	2,1	1,3	37º
37º	Pínzio - Alto de Leomil	SD	2,0	1,1	39º
38º	Vouzela Poente - Vouzela Nascente	SD	2,0	1,3	38º
39º	EN2 - Caçador	SC	1,6	0,9	41º
40º	EN2 - Caçador	SD	1,0	0,6	42º
41º	Ratoeira Poente - Ratoeira Nascente	SC	0,9	1,0	40º
42º	Ratoeira Poente - Ratoeira Nascente	SD	0,8	0,6	43º
43º	Guarda - Pinhel	SC	0,7	1,6	32º
44º	Guarda - Pinhel	SD	0,7	0,4	44º
45º	Celorico - EN17	SD	0,4	0,1	49º
46º	Boa Aldeia Poente - Boa Aldeia Nascente	SC	0,4	0,3	45º
47º	Celorico - EN17	SC	0,4	0,1	48º
48º	Boa Aldeia Poente - Boa Aldeia Nascente	SD	0,3	0,3	46º
49º	Ratoeira Nascente - IP2/A25	SC	0,2	0,0	50º
50º	Ratoeira Nascente - IP2/A25	SD	0,2	0,3	47º

ANEXO E.2 – SUBLANÇOS COM MAIOR MÉDIA DE ACIDENTES TOTAIS OBSERVADA ENTRE 2015 E 2021

Posição	Localização	Sentido	Média observada Acidentes Totais (2015-2021)
1º	Carvoeiro - Talhadas	SD	14,0
2º	Caçador - Fagilde	SC	6,9
3º	Carvoeiro - Talhadas	SC	6,3
4º	Fagilde - Mangualde	SD	6,1
5º	Fornos de Algodres - Celorico	SC	5,9
6º	Caçador - Fagilde	SD	5,6
7º	Talhadas - Reigoso	SD	5,3
8º	Pinhel - Pínzio	SC	4,9
9º	Boa Aldeia Nascente - Fail (A24/A25)	SC	3,9
10º	Mangualde - Chãs de Tavares	SD	3,9
11º	Chãs de Tavares - Fornos de Algodres	SD	3,6
12º	EN17 - Ratoeira Poente	SC	3,6
13º	IC2 (EN1) - Carvoeiro	SC	3,6
14º	Reigoso - Cambarinho	SD	3,6
15º	IP2/A25 - Guarda	SD	3,4
16º	Boa Aldeia Nascente - Fail (A24/A25)	SD	3,1
17º	Cambarinho - Vouzela Poente	SC	3,0
18º	Talhadas - Reigoso	SC	2,9
19º	Fagilde - Mangualde	SC	2,6
20º	Pinhel - Pínzio	SD	2,6
21º	Alto de Leomil - Vilar Formoso	SD	2,3
22º	Fornos de Algodres - Celorico	SD	2,3
23º	IP2/A25 - Guarda	SC	2,3
24º	Reigoso - Cambarinho	SC	2,3
25º	Ventosa - Boa Aldeia Poente	SD	2,3
26º	Vouzela Nascente - Ventosa	SC	2,3
27º	Cambarinho - Vouzela Poente	SD	2,1
28º	IC2 (EN1) - Carvoeiro	SD	2,0
29º	Mangualde - Chãs de Tavares	SC	2,0
30º	Pínzio - Alto de Leomil	SC	1,9
31º	Alto de Leomil - Vilar Formoso	SC	1,6

32º	Guarda - Pinhel	SC	1,6
33º	Chãs de Tavares - Fornos de Algodres	SC	1,4
34º	Ventosa - Boa Aldeia Poente	SC	1,4
35º	EN17 - Ratoeira Poente	SD	1,3
36º	Vouzela Nascente - Ventosa	SD	1,3
37º	Vouzela Poente - Vouzela Nascente	SC	1,3
38º	Vouzela Poente - Vouzela Nascente	SD	1,3
39º	Pínzio - Alto de Leomil	SD	1,1
40º	Ratoeira Poente - Ratoeira Nascente	SC	1,0
41º	EN2 - Caçador	SC	0,9
42º	EN2 - Caçador	SD	0,6
43º	Ratoeira Poente - Ratoeira Nascente	SD	0,6
44º	Guarda - Pinhel	SD	0,4
45º	Boa Aldeia Poente - Boa Aldeia Nascente	SC	0,3
46º	Boa Aldeia Poente - Boa Aldeia Nascente	SD	0,3
47º	Ratoeira Nascente - IP2/A25	SD	0,3
48º	Celorico - EN17	SC	0,1
49º	Celorico - EN17	SD	0,1
50º	Ratoeira Nascente - IP2/A25	SC	0,0