



**MODELOS DE PREVISÃO DE ACIDENTES EM RODOVIA  
BRASILEIRA DE PISTA DUPLA**

**PHILIPPE BARBOSA SILVA**

**TESE DE DOUTORADO EM TRANSPORTES  
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**FACULDADE DE TECNOLOGIA  
UNIVERSIDADE DE BRASÍLIA**

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**MODELOS DE PREVISÃO DE ACIDENTES EM RODOVIA  
BRASILEIRA DE PISTA DUPLA**

**PHILIPPE BARBOSA SILVA**

**ORIENTADORA: MICHELLE ANDRADE  
COORIENTADORA: SARA MARIA PINHO FERREIRA**

**TESE DE DOUTORADO EM TRANSPORTES**

**PUBLICAÇÃO: T.TD-007/2019  
BRASÍLIA/DF: DEZEMBRO/2019**

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**MODELOS DE PREVISÃO DE ACIDENTES EM RODOVIA  
BRASILEIRA DE PISTA DUPLA**

**PHILIPPE BARBOSA SILVA**

**TESE DE DOUTORADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA OBTENÇÃO DO GRAU DE DOUTOR EM TRANSPORTES.**

**APROVADA POR:**

---

**MICHELLE ANDRADE, Dra., (UnB)  
(ORIENTADORA)**

---

**SARA MARIA PINHO FERREIRA, Dra., (U.Porto - Portugal)  
(ORIENTADORA)**

---

**MARIA ALICE PRUDÊNCIO JACQUES, PhD, (UnB)  
(EXAMINADORA INTERNA)**

---

**FLÁVIO JOSÉ CRAVEIRO CUNTO, PhD (UFC)  
(EXAMINADOR EXTERNO I)**

---

**ELISABETE FRAGA DE FREITAS, Dra., (UMinho - Portugal)  
(EXAMINADORA EXTERNA II)**

**BRASÍLIA/DF, 06 de DEZEMBRO de 2019.**

## FICHA CATALOGRÁFICA

SILVA, PHILIPPE BARBOSA

Modelos de Previsão de Acidentes em Rodovia Brasileira de Pista Dupla [Distrito Federal] 2019.

xxii, 320p., 210 x 297 mm (ENC/FT/UnB, Doutor, Transportes, 2019).

Tese de Doutorado – Universidade de Brasília. Faculdade de Tecnologia.  
Departamento de Engenharia Civil e Ambiental.

- |                                     |   |
|-------------------------------------|---|
| 1. Modelos de previsão de acidentes | 2. Frequência de acidentes por severidade |
| 3. Extensão do segmento             | 4. Redes neurais artificiais              |
| I. ENC/FT/UnB                       | II. Título (série)                        |

## REFERÊNCIA BIBLIOGRÁFICA

SILVA, P. B. (2019). Modelos de Previsão de Acidentes em Rodovia Brasileira de Pista Dupla, Publicação T.TD-007/2019, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 320p.

## CESSÃO DE DIREITOS

AUTOR: Philippe Barbosa Silva.

TÍTULO DA TESE: Modelos de Previsão de Acidentes em Rodovia Brasileira de Pista Dupla.

GRAU: Doutor ANO: 2019

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta tese de doutorado pode ser reproduzida sem autorização por escrito do autor.

---

Philippe Barbosa Silva  
SQN 306, Bloco C, Apartamento 503, Asa Norte  
Brasília, DF, Brasil 70745-030

## AGRADECIMENTOS

Toda minha gratidão e louvor ao Senhor, o Deus Vivo, que deu-me a conhecer o seu amor, misericórdia e graça, e que foi meu refúgio e fortaleza em todos os momentos do doutorado. Toda honra e toda glória seja dada a Ele.

Agradeço aos meus pais Vânia e Aildo pelo apoio, incentivo, dedicação e amor de sempre. Estendo os agradecimentos aos meus tios Marcello e Sandra que foram meus “pais” em Brasília. Aos meus irmãos Soraya, Vilmar, Melissa e Augusto, e aos meus avós Maria José e Paulo Costa também presto meus agradecimentos.

À Anna, por todo amor, compreensão e estímulo na fase final do doutorado, minha gratidão. Aos queridos irmãos da Igreja Cristã Maranata que, por todos os lugares onde passei, me apoiaram com orações, assistência e fraterno amor, meus sinceros agradecimentos. Vocês são minha família em Cristo e participantes dessa conquista.

Agradeço à professora Michelle que, para além de orientadora, foi uma amiga sempre disponível e prestativa, tendo me acompanhado ao longo da última década da minha trajetória acadêmica. E agora nessa nova fase, certamente prosseguiremos com a parceira. Também agradeço à professora Sara pela coorientação. Fui bem recebido e assistido no período em que estive no Porto, o que foi determinante para que tenha sido uma experiência tão proveitosa como foi.

Agradeço ao Instituto Federal Goiano (IF Goiano) pela minha liberação e incentivo para cursar o doutorado, apresentando agradecimento especial ao Prof. Alan Costa (Diretor de Pesquisa, Pós-Graduação e Inovação do *Campus* Rio Verde) e ao Prof. Fabiano Guimarães (Pró-reitor de Pesquisa, Pós-Graduação e Inovação). O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, na modalidade de bolsa de doutorado sanduíche no exterior, pelo que também agradeço.

Agradeço aos professores do Programa de Pós-Graduação em Transportes da UnB (PPGT) pela contribuição em minha formação e também aos que participaram das diversas bancas e colaboraram para a melhoria desta tese. Também um agradecimento especial à Camila, secretária do PPGT, sempre gentil e eficiente em suas atribuições.

Agradeço aos colegas e amigos do PPGT, especialmente à Adriana (Fia), Rogério (Big Roger), Hernany (Hernanys), Janneth (Janneths), Edwin e Wesley (meus caros) pelo apoio ao longo da caminhada. Também aos colegas da Faculdade de Engenharia da Universidade do Porto (FEUP) agradeço pelo acolhimento enquanto estive em Portugal.

Meus agradecimentos a todos os órgãos que apoiaram este trabalho, em especial à Agência Nacional de Transportes Terrestres (ANTT), e ao servidor Henrique Vasconcelos, pela disponibilização de dados e auxílio ao desenvolvimento desta pesquisa. Também agradeço a todos professores, pesquisadores e especialistas que foram consultados e contribuíram de alguma forma com o trabalho, destacando o Prof. Jonathan Agüero-Valverde (Universidade da Costa Rica) e o Ícaro Miranda (PPCA/UnB) pela ajuda essencial no processo de modelagem.

Por fim, a todos que de alguma forma (mesmo que mínima) contribuíram com este trabalho, meu muito obrigado!

*“Não a nós, SENHOR, nenhuma glória para nós, mas sim ao teu nome, por teu amor e por tua fidelidade.” (Salmos 115:1)*

## RESUMO

### MODELOS DE PREVISÃO DE ACIDENTES EM RODOVIA BRASILEIRA DE PISTA DUPLA

A modelagem da segurança viária é uma importante estratégia para o gerenciamento da segurança viária (GSV). O desenvolvimento de modelos de resposta multivariada (consideração simultânea de ocorrência de acidentes de diferentes níveis de severidade) também tem grande utilidade e carece de exploração. Um desafio inicial na previsão de frequência de acidentes é a estratégia de segmentação da rodovia, especialmente quanto a extensão do segmento. Em relação a abordagem metodológica, técnicas de aprendizado de máquina (AM), especialmente redes neurais artificiais (RNA), são apresentadas como potencial alternativa. Diante disso, o estudo desenvolvido buscou avaliar o potencial de utilização de técnicas de AM para o desenvolvimento de modelos de previsão de frequência de acidentes segundo três níveis de severidade, e ainda, avaliar a influência da extensão do segmento no desenvolvimento deste tipo de modelo. O trecho de rodovia de pista dupla analisado foi segmentado em 10 diferentes extensões fixas, sendo caracterizado por variáveis de geometria, operação e pavimento, nos períodos 2011-2014 e 2015-2018. Para fins comparativos, foi empregado o modelo multivariado Poisson lognormal (MVPLN) no processo de modelagem. Todos os modelos desenvolvidos tiveram a validade replicativa investigada e, destes, foram selecionados os melhores modelos que foram, também, verificados em termos da validação preditiva e estrutural. Esse procedimento permitiu confirmar a adequação do uso de RNA para a modelagem proposta – com ligeira superioridade à outra abordagem –, mas também revelou limitações dessa técnica. De igual modo, as vantagens e fragilidades dos modelos MVPLN também foram conhecidas. Assim foi possível concluir que duas técnicas são adequadas para a modelagem da segurança viária, devendo ser empregada aquela que melhor se adeque ao propósito do estudo em questão, ou ainda, considerar a associação entre elas.

**Palavras-chave:** modelos de previsão de acidentes; frequência de acidentes por severidade; extensão do segmento; redes neurais artificiais; modelo multivariado Poisson lognormal.



## ABSTRACT

### CRASH PREDICTION MODELS FOR BRAZILIAN MULTILANE HIGHWAY

Road Safety Modeling is an important strategy for road safety management (RSM). The development of multivariate response models (considering the simultaneous occurrence of crashes with different levels of severity) is also of great usefulness and lacks exploration. An initial challenge in crash prediction models is the highway segmentation method, mainly concerning segment lengths. Regarding the methodological approach, machine learning (ML) techniques, especially artificial neural networks (ANN), are presented as a possible alternative. Therefore, this study aimed to evaluate the potential of using ML techniques to develop crash prediction models in terms of three levels of severity and, besides that, evaluate how length segmentation influences this type of model. The data consisted of a multilane highway, which was divided in 10 different fixed lengths, being characterized by means of geometric, operational and paving characteristics, in two periods: 2011-2014 and 2015-2018. For comparison, the multivariate Poisson lognormal model (MVPLN) was used. All the developed models had their replicative validation tested and, among these, the best models were selected, which were also verified in terms of predictive and structural validations. This procedure allowed to assure the properness of using ANN for the proposed modelling – being slightly superior to the other approach – but also showed limitations of this technique. Similarly to that, the pros and cons of the MVPLN were highlighted. Thus, it was possible to conclude that both techniques are proper for modeling road safety, and it is necessary to apply the one that better fits the purpose of the study in question or even consider an association between them.

**Keywords:** Crash prediction models, crash frequency per severity, segment length, artificial neural networks, multivariate Poisson lognormal model.

# ÍNDICE

1. INTRODUÇÃO.....	1
1.1. PROBLEMA E QUESTÕES DE PESQUISA .....	4
1.2. OBJETIVOS.....	5
1.3. ESTRUTURA.....	5
2. MODELAGEM DA SEGURANÇA VIÁRIA .....	7
2.1. MODELAGEM ESTATÍSTICA DA SEGURANÇA VIÁRIA.....	8
2.2. MODELAGEM DA SEGURANÇA VIÁRIA COM MODELOS MULTIVARIADOS .....	10
2.3. MODELAGEM DA SEGURANÇA VIÁRIA COM TÉCNICAS DE APRENDIZADO DE MÁQUINA .....	11
2.3.1. Abordagens Metodológicas .....	12
2.3.2. Redes Neurais Artificiais.....	18
2.4. VARIÁVEIS EXPLICATIVAS .....	24
2.5. SEGMENTAÇÃO DA RODOVIA.....	28
3. MÉTODO .....	31
3.1. ETAPA 1 - ENTENDIMENTO DO DOMÍNIO.....	31
3.2. ETAPA 2 - ENTENDIMENTO E PREPARAÇÃO DOS DADOS.....	32
3.3. ETAPA 3 - MODELAGEM.....	34
3.3.1. Aprendizado de máquina.....	34
3.3.2. Modelo multivariado Poisson lognormal (MVPLN).....	35
3.4. ETAPA 4 – AVALIAÇÃO .....	36
3.5. ETAPA 5 – APLICAÇÃO .....	38
4. DESCRIÇÃO DA INFORMAÇÃO INTEGRADA NAS BASES DE DADOS.....	40
4.1. ENTENDIMENTO DO DOMÍNIO .....	40
4.2. ENTENDIMENTO DOS DADOS.....	41
4.3. PREPARAÇÃO DOS DADOS .....	44
4.3.1. Variáveis Explicativas .....	45
4.3.2 Construção das Bases de Dados .....	55
4.4. ESTATÍSTICA DESCRITIVA DOS SEGMENTOS .....	57
5. MODELAGEM E VALIDAÇÃO .....	67
5.1. MODELAGEM .....	67
5.1.1. Redes Neurais Artificiais.....	67
5.1.2. Modelo multivariado Poisson lognormal (MVPLN).....	75
5.2. VALIDAÇÃO .....	78
5.2.1. Validação Replicativa.....	81
5.2.2. Validação Preditiva .....	81
5.2.3. Métodos Empregados para Validação Replicativa e Preditiva.....	82
5.2.4. Validação Estrutural .....	85
6. ANÁLISE DOS RESULTADOS .....	96

6.1. VALIDAÇÃO REPLICATIVA .....	97
6.1.1. Redes Neurais Artificiais.....	97
6.1.2. Modelo Multivariado Poisson lognormal.....	110
6.1.3. Previsão do número de acidentes com mortes.....	118
6.1.4. Análise Comparativa dos Modelos.....	125
6.2. VALIDAÇÃO PREDITIVA .....	132
6.3. VALIDAÇÃO ESTRUTURAL .....	138
6.3.1. Validação dos Modelos de RNA .....	140
6.3.2. Coeficientes Estimados dos Modelos MVPLN.....	161
6.4. CONSIDERAÇÕES FINAIS .....	174
7. RANQUEAMENTO E IDENTIFICAÇÃO DE SEGMENTOS CRÍTICOS .....	177
7.1. PROCEDIMENTO PARA RANQUEAMENTO E IDENTIFICAÇÃO DE SEGMENTOS CRÍTICOS.....	177
7.1.1. Número Total de Acidentes.....	178
7.1.2. Taxa de Severidade dos Acidentes .....	178
7.1.3. Custo Médio de Acidentes .....	180
7.1.4. Análises .....	182
7.2. RESULTADOS DO RANQUEAMENTO E IDENTIFICAÇÃO DE SEGMENTOS CRÍTICOS.....	183
7.2.1. Número Total de Acidentes.....	184
7.2.2. Taxa de Severidade dos Acidentes .....	186
7.2.3. Custo Médio Total dos Acidentes .....	189
7.2.4. Considerações Finais .....	196
8. CONCLUSÕES E RECOMENDAÇÕES .....	199
8.1. SÍNTESE GERAL.....	199
8.2. CONCLUSÕES.....	201
8.3. LIMITAÇÕES .....	207
8.4. RECOMENDAÇÕES.....	208
APÊNDICE A – REVISÃO SISTEMÁTICA DA LITERATURA.....	233
A.1. INTRODUÇÃO.....	234
A.2. PLANEJAMENTO .....	234
A.3. CONDUÇÃO .....	235
A.3.1. Trabalhos Identificados .....	237
A.3.2. Trabalhos Selecionados.....	238
A.4.1. Redes Neurais Artificiais e Redes Bayesianas .....	246
A.4.2. Árvores de Decisão .....	249
A.4.3. Máquina de Vetores de Suporte .....	251
A.4.4. Programação Genética.....	251
A.4.5. Demais Técnicas.....	252
A.4.6. Modelos de Previsão de Acidentes por Severidade.....	253
A.4.7. Modelos de Previsão de Frequência de Acidentes .....	267
A.4.8. Modelos de Previsão de Frequência e Severidade de Acidentes.....	276
A.4.9 Considerações Finais.....	279

APÊNDICE B – MODELAGEM EXPLORATÓRIA DOS DADOS COM TÉCNICAS DE APRENDIZADO DE MÁQUINA.....	282
B.1. MODELAGEM EXPLORATÓRIA.....	283
B.1.1. Regularização das Variáveis.....	283
B.1.2. Testes Exploratórios com Regressores .....	284
B.2. RESULTADOS DA MODELAGEM EXPLORATÓRIA.....	285
B.2.1. Regularização dos Dados .....	286
B.2.2. Testes Exploratórios com Regressores .....	287
APÊNDICE C – ESTATÍSTICA DESCRITIVA, GRÁFICOS DE QUALIDADE DE AJUSTE E ANÁLISE DE RESÍDUOS COMPLEMENTARES.....	291

## LISTA DE TABELAS

Tabela 2.1 - Descrição geral dos artigos sistematizados .....	14
Tabela 2.2 - Resumo das características das RNA para modelagem da segurança viária .....	22
Tabela 2.3 - Principais variáveis explicativas utilizadas nos modelos.....	26
Tabela 2.4 - Principais fatores contribuintes para severidade ou ocorrência de acidentes .....	27
Tabela 4.2 - Identificação, categorização e seleção de dados .....	43
Tabela 4.3 - Descrição das concessões administradas pela ANTT .....	44
Tabela 4.4 - Descrição das variáveis explicativas e variáveis dependentes.....	56
Tabela 4.5 - Distribuição do número de segmentos e observações.....	57
Tabela 5.1 - Número de neurônios e camadas ocultas para cada extensão de segmento.....	69
Tabela 5.2 – Resumo dos parâmetros da rede neural .....	74
Tabela 5.3 – Número de iterações da simulação de MCMC para cada extensão de segmento	78
Tabela 6.1 – Medidas de desempenho dos modelos ajustados para Pista Norte, com uso de redes neurais.....	100
Tabela 6.2 - Medidas de desempenho dos modelos ajustados para Pista Sul, com uso de redes neurais .....	100
Tabela 6.3 - Síntese dos resultados da análise gráfica dos modelos da Pista Norte (RNA)...	103
Tabela 6.4 – Síntese dos resultados da análise gráfica dos modelos da Pista Sul (RNA).....	104
Tabela 6.5 – Medidas de desempenho dos modelos ajustados para Pista Norte, com uso de MVPLN.....	111
Tabela 6.6 – Medidas de desempenho dos modelos ajustados para Pista Sul, com uso de MVPLN.....	111
Tabela 6.7– Síntese dos resultados da análise gráfica dos modelos da Pista Norte (MVPLN) .....	112
Tabela 6.8 – Síntese dos resultados da análise gráfica dos modelos da Pista Sul (MVPLN)	113
Tabela 6.9 – Diferença percentual entre as medidas de desempenho dos modelos ajustados com uso de RNA e MVPLN, para Pista Norte.....	126
Tabela 6.10 - Diferença percentual entre as medidas de desempenho dos modelos ajustados com uso de RNA e MVPLN, para Pista Sul .....	126
Tabela 6.11– Comparação das medidas de desempenhos dos modelos de RNA e MVPLN selecionados para Pista Norte.....	127
Tabela 6.12 – Medidas de desempenho de validação dos modelos selecionados.....	133
Tabela 6.13 – Estatísticas descritivas dos dados previstos e observados dos modelos selecionados .....	134
Tabela 6.14– Coeficientes estimados dos modelos MVPLN selecionados para Pista Norte.	162
Tabela 6.15 – Coeficientes estimados dos modelos MVPLN selecionados para Pista Sul ...	163
Tabela 6.16 - Relacionamento das variáveis com cada tipo de acidente .....	165

Tabela 6.17– Resultados dos passos executados na seleção backward.....	170
Tabela 6.18 - Coeficientes estimados para modelos resultantes da seleção de variáveis -MVPLN .....	171
Tabela 6.19 – Comparação entre métricas dos modelos originais e modelos resultantes da seleção de variáveis – MVPLN .....	172
Tabela 7.1– Ranqueamento de segmentos em termos de número total de acidentes acumulados .....	185
Tabela 7.2– Ranqueamento de segmentos em termos da Taxa de Severidade dos acidentes	187
Tabela 7.3– Número de segmentos críticos identificados.....	188
Tabela 7.4 – Custo médio de acidentes por tipo de severidade.....	189
Tabela 7.5 – Ranqueamento de segmentos da Pista Norte em termos de custo médio total de acidente.....	191
Tabela 7.6 – Ranqueamento de segmentos da Pista Sul em termos de custo médio total de acidente.....	192
Tabela 7.7– Fator de gravidade dos segmentos críticos e segmentos prioritários da Pista Norte .....	193
Tabela 7.8 - Fator de gravidade dos segmentos críticos e segmentos prioritários da Pista Sul .....	195
Tabela A.1 - Condução da RSL .....	235
Tabela A.2 - Relação de estudos identificados .....	237
Tabela A.3 - Relação de artigos publicados em periódicos, por ano .....	239
Tabela A.4- Relação de número de trabalhos publicados por país (primeiro autor)/por ano	240
Tabela A. 5 - Tipo de modelagem e técnicas utilizadas nos artigos selecionados.....	243
Tabela A.6 - Tipo de modelagem e técnicas utilizadas nos artigos selecionados.....	247
Tabela A.7- Quantidade de dados e área de estudo de cada modelo de previsão de acidentes por severidade.....	254
Tabela A.8- Variáveis explicativas e variáveis de saída de cada modelo de previsão de acidentes por severidade .....	258
Tabela A.9 - Variáveis explicativas e variáveis de saída de cada modelo de previsão de acidentes por severidade .....	265
Tabela A.10 - Quantidade de dados e área de estudo de cada modelo de frequência de acidentes .....	268
Tabela A.11 - Variáveis explicativas e variáveis de saída de cada modelo de frequência de acidentes .....	270
Tabela A.12- Variáveis explicativas e variáveis de saída de cada modelo de frequência de acidentes.....	275
Tabela A.13 - Quantidade de dados e área de estudo de cada modelo de frequência e severidade de acidentes .....	276
Tabela A.14- Variáveis explicativas e variáveis de saída de cada modelo de frequência e severidade de acidentes .....	277

Tabela A. 15 - Variáveis explicativas e variáveis de saída de cada modelo de frequência ... 279

Tabela C. 1 – Estatística descritiva dos segmento de 3,5 km da Pista Norte e 4 km da Pista Sul  
.....292

## LISTA DE FIGURAS

Figura 1.1 - Definição gráfica de acidente de trânsito .....	2
Figura 1.2- Estrutura da tese .....	6
Figura 2.1- Linha do tempo dos artigos sistematizados .....	12
Figura 2.2 - Ilustração dos processos de Aprendizagem de Máquina .....	17
Figura 2.3 - Estrutura típica de uma RNA feedforward com três camadas .....	20
Figura 2.4- Grupos de variáveis utilizadas na modelagem de acidentes por severidade .....	25
Figura 2.5- Grupos de variáveis utilizadas na modelagem de frequência de acidentes .....	25
Figura 3.1 - Método adotado na pesquisa .....	31
Figura 3.2- Etapas da modelagem com técnica de aprendizado de máquina .....	34
Figura 3.3 - Etapas da modelagem com técnica de aprendizado de máquina .....	36
Figura 4.1 - Mapa da concessão Nova Dutra .....	40
Figura 4.2 - Acidentalidade no período 2011-2018 no trecho da BR-116/SP/RJ .....	41
Figura 4.3 - Eixo da rodovia e detalhes da segmentação .....	44
Figura 4.4 – Matriz de correlação entre as variáveis explicativas, para Pista Norte, período 2011-2014.....	54
Figura 4.5 - Composição das bases de dados .....	57
Figura 4.6 – Distribuição das variáveis segundo cada extensão de segmento, na Pista Norte, no período 2011-2014 .....	59
Figura 4.7 – Distribuição das variáveis segundo cada extensão de segmento, na Pista Norte, no período 2015-2018 .....	60
Figura 4.8 – Distribuição das variáveis segundo cada extensão de segmento, na Pista Sul, no período 2011-2014 .....	61
Figura 4.9 – Distribuição das variáveis segundo cada extensão de segmento, na Pista Sul, no período 2015-2018 .....	62
Figura 4.10 – Histogramas dos tipos de acidentes ocorridos por ano, em segmentos de 500 m, para diferentes pistas e períodos de tempo.....	64
Figura 4.11 – Histogramas do volume de tráfego em segmentos de 500 m, para diferentes pistas e períodos de tempo.....	65
Figura 4.12– Relação entre exposição e acidentes, segmentos de 500 m, PN, 2011-2014.....	66
Figura 4.13 – Relação entre exposição e acidentes, segmentos de 500 m, PS, 2011-2014 .....	66
Figura 5.1 - Comportamento de diferentes funções de ativação .....	71
Figura 5.2– Esquema de validação holdout dos modelos .....	75
Figura 5.3 – Protocolo de validação de modelos RNA .....	80
Figura 5.4 – Procedimento do Método do Sobol’ .....	88
Figura 5.5 – Procedimento do Método de Morris .....	90



Figura 5.6 - Esquema explicativo do método de perfil de sensibilidade.....	92
Figura 5.7 - Esquema geral Random Forest .....	92
Figura 6.1 - Procedimento geral de validação dos modelos .....	96
Figura 6.2 – Erro relativo dos modelos para Pista Norte, com uso de redes neurais .....	98
Figura 6.3 – Erro relativo dos modelos para Pista Sul, com uso de redes neurais.....	98
Figura 6. 4 – Qualidade de ajuste e análise de resíduos para PN_500m_2011_2014 (RNA)	102
Figura 6.5 – CURE Plot (RNA) – Pista Norte, 500 m .....	106
Figura 6.6 – CURE Plot (RNA) – Pista Norte, 3,5 km .....	107
Figura 6.7 – CURE Plot (RNA) – Pista Sul, 500m.....	108
Figura 6. 8 – CURE Plot (RNA) – Pista Sul, 4 km.....	109
Figura 6.9 - CURE Plot (MVPLN) – Pista Norte, 500 m .....	114
Figura 6.10 – CURE Plot (MVPLN) – Pista Norte, 3,5 km.....	115
Figura 6.11 – CURE Plot (MVPLN) – Pista Sul, 500 m .....	116
Figura 6.12 – CURE Plot (MVPLN) – Pista Sul, 4 km .....	117
Figura 6.13 – Pirâmide de Hydén.....	121
Figura 6.14– Proporção entre acidentes sem vítimas e com vítimas nos dados observados..	121
Figura 6.15 – NASV e NASV ajustado pela proporção NASV/NACV para PN_3,5km_2011_2014.....	122
Figura 6.16 – Estimativa indireta dos acidentes com mortes .....	123
Figura 6. 17– Matriz de confusão da estimativa indireta dos acidentes com mortes (ACM)	124
Figura 6. 18 - CURE Plot resultantes de modelos de previsão de acidentes no contexto brasileiro empregando-se o método do HSM.....	130
Figura 6.19– Comparação direta entre valores observados e previstos no conjunto de validação dos modelos da Pista Norte .....	135
Figura 6.20 – Comparação direta entre valores observados e previstos no conjunto de validação dos modelos da Pista Sul.....	135
Figura 6.21– Representação do dilema viés-variância.....	139
Figura 6.22 – Índices de Sobol’ dos modelos da Pista Norte.....	141
Figura 6.23 – Índices de Sobol’ dos modelos da Pista Sul .....	144
Figura 6.24 – Valores da média dos efeitos elementares para NASV .....	145
Figura 6.25 – Valores da média dos efeitos elementares para NACV .....	146
Figura 6.26 – Valores da média dos efeitos elementares para NACM .....	147
Figura 6.27 – Diagrama de Morris para modelos da Pista Norte.....	148
Figura 6.28 – Diagrama de Morris para modelos da Pista Sul.....	149
Figura 6.29 – Perfil de sensibilidade das variáveis explicativas – PN_3,5km_2011_2014...	152
Figura 6.30 – Perfil de sensibilidade das variáveis VDMA, IRH e N_saídas – PN_3,5km_2011_2014.....	154

Figura 6.31– Fatores de importância dos modelos selecionados da Pista Norte.....	156
Figura 6.32 – Fatores de importância dos modelos selecionados da Pista Sul .....	157
Figura 6.33- Gráfico de dispersão entre valores previstos de acidentes (sem vítimas e com vítimas) pelo modelo original e modelo após seleção de variáveis – PS_4km_2011_2014..	172
Figura 7.1– Procedimento geral para ranqueamento e identificação de segmentos críticos.....	183
Figura 7.2 – Número total de acidentes observados versus número total de acidentes previstos pelos modelos RNA e MVPLN.....	184
Figura 7.3 – Taxa de severidade dos acidentes observada versus taxa de severidade dos acidentes prevista a partir dos modelos RNA e MVPLN.....	186
Figura 7.4 – Custo médio total de acidentes para dados observados versus custo médio total de acidentes para dados previstos (modelos RNA e MVPLN).....	189
Figura 8.1– Resumo gráfico da tese .....	199
Figura 8.2 – Procedimento geral para desenvolvimento de modelos de previsão de acidentes em rodovias com o uso de técnica de aprendizado de máquina.....	207
Figura A.1- Esquema geral do procedimento de revisão .....	234
Figura A.2- Relação temporal e continental de publicações em periódicos .....	240
Figura A.3 - Relação temporal e continental de valores acumulados de publicações em periódicos .....	241
Figura A.4 - Proporção dos tipos de modelagens identificadas .....	242
Figura A.5- Tipos de técnicas empregadas. ....	245
Figura A.6- Proporção dos tipos de modelagens identificadas .....	245
Figura A.7 - Países com artigos de modelagem de acidentes por severidade selecionados ..	253
Figura A.8- Técnicas utilizada na modelagem de acidentes por severidade.....	253
Figura A.9- Distribuição das variáveis explicativas por emprego nos estudos, número de variáveis e número de ocorrências, na modelagem de acidentes por severidade.....	257
Figura A.10 - Distribuição dos fatores viário-ambientais na modelagem de acidentes por severidade.....	257
Figura A.11- Distribuição das variáveis de caracterização do acidente na modelagem de acidentes por severidade.....	260
Figura A.12 - Distribuição dos fatores humanos na modelagem de acidentes por severidade .....	260
Figura A.13- Distribuição dos fatores veiculares na modelagem de acidentes por severidade .....	260
Figura A.14- Distribuição das variáveis de entrada de todos os modelos de previsão de acidentes por severidade .....	262
Figura A.15- Classes-resposta dos modelos de previsão de acidente por severidade .....	263
Figura A.16- Países com artigos de modelos de previsão de frequência de acidentes .....	267
Figura A.17- Técnicas utilizada na modelagem de frequência de acidentes .....	267

Figura A.18- Distribuição das variáveis explicativas por emprego nos estudos, número de variáveis e número de ocorrências, na modelagem de frequência de acidentes.....	271
Figura A.19- Distribuição dos fatores viário-ambientais na modelagem de frequência de acidentes.....	272
Figura A.20- Distribuição das variáveis de caracterização do acidente na modelagem de frequência de acidentes .....	272
Figura A.21- Distribuição das variáveis de entrada de todos os modelos de frequência de acidentes.....	274
Figura B.1– Desempenho das diferentes alternativas de regularização dos dados para as respostas NASV, NACV e NACM, para Pista Norte, período 2011-2014. ....	286
Figura B.2 - Desempenho das diferentes alternativas de regularização dos dados para as respostas NASV, NACV e NACM .....	287
Figura B.3 – Desempenho dos modelos para PS, período 2015-2018, com uso de kNN regressor e Random Forest.....	288
Figura B.4 – Desempenho dos modelos para PS, período 2015-2018, com uso de kNN regressor e Random Forest.....	289
Figura C.1 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_500m_2011_2014 (RNA).....	294
Figura C.2 - Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_500m_2015_2018 (RNA).....	295
Figura C.3 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_3,5km_2011_2014 (RNA).....	296
Figura C.4 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_3,5km_2015_2018 (RNA).....	297
Figura C.5 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS_500m_2011_2014 (RNA) .....	298
Figura C.6 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS_500m_2015_2018 (RNA) .....	299
Figura C.7 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS_4km_2011_2014 (RNA) .....	300
Figura C.8 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS_4km_2015_2018 (RNA) .....	301
Figura C.9 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_500m_2011_2014 (MVPLN).....	302
Figura C.10 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_500m_2015_2018 (MVPLN).....	303
Figura C.11 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_3,5km_2011_2014 (MVPLN).....	304
Figura C.12 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_3,5km_2015_2018 (MVPLN).....	305
Figura C.13 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS_500m_2011_2014 (MVPLN).....	306

Figura C.14 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS_500m_2015_2018 (MVPLN).....	307
Figura C.15 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS_4km_2011_2014 (MVPLN).....	308
Figura C.16 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS_4km_2015_2018 (MVPLN).....	309
Figura C.17– Perfil de sensibilidade das variáveis explicativas – PN_3,5km_2015_2018...	310
Figura C.18 – Perfil de sensibilidade das variáveis explicativas – PS_4km_2011_2014.....	311
Figura C.19 – Perfil de sensibilidade das variáveis explicativas – PS_4km_2015_2018.....	312
Figura C.20 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_3,5km_2011_2014 (RNA – validação) .....	313
Figura C.21 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_3,5km_2015_2018 (RNA – validação) .....	314
Figura C.22 – Qualidade de ajuste ( <i>goodness-of-fit</i> ) e análise de resíduos para PS_4km_2011_2014 (RNA – validação).....	315
Figura C.23 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS_4km_2015_2018 (RNA – validação).....	316
Figura C.24 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_3,5km_2011_2014 (MVPLN – <i>backward</i> ) .....	317
Figura C.25– Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN_3,5km_2015_2018 (MVPLN – <i>backward</i> ) .....	318
Figura C.26 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS_4km_2011_2014 (MVPLN – <i>backward</i> ).....	319
Figura C.27 – Qualidade de ajuste ( <i>goodness-of-fit</i> ) e análise de resíduos para PS_4km_2015_2018 (MVPLN – <i>backward</i> ).....	320

## LISTA DE QUADROS

Quadro 5.1 - Medidas de desempenho e análises gráficas empregadas para validação replicativa e preditiva.....	82
Quadro 5.2 – Métricas utilizadas para validação replicativa e preditiva dos modelos .....	83
Quadro 5.3 – Elementos gráficos utilizados para validação replicativa e preditiva dos modelos .....	84
Quadro 6.1 – Síntese dos resultados da análise de sensibilidade dos modelos de RNA para Pista Norte.....	159
Quadro 6.2 – Síntese dos resultados da análise de sensibilidade dos modelos de RNA para Pista Sul.....	160
Quadro C.1 - Descrição dos elementos gráficos complementares de avaliação dos modelos.....	293

## LISTA DE SIGLAS E ABREVIATURAS

AM	Aprendizado de máquina
ANTT	Agência Nacional de Transportes Terrestres
DNIT	Departamento Nacional de Infraestrutura de Transportes
MPA	Modelos de previsão de acidentes
MVPLN	Modelo multivariado Poisson lognormal
NACM	Número de acidentes com mortes
NACV	Número de acidentes com vítimas
NASV	Número de acidentes sem vítimas
NTA	Número total de acidentes
PN	Pista Norte
PN_3,5km_2011_2014	Modelo com segmentos de extensão 3,5 km da Pista Norte, no período de 2011 a 2014
PN_3,5km_2015_2018	Modelo com segmentos de extensão 3,5 km da Pista Norte, no período de 2015 a 2018
PN_500m_2011_2014	Modelo com segmentos de extensão 500 m da Pista Norte, no período de 2011 a 2014
PN_500m_2015_2018	Modelo com segmentos de extensão 500 m da Pista Norte, no período de 2015 a 2018
PS	Pista Sul
PS_4km_2011_2014	Modelo com segmentos de extensão 4 km da Pista Sul, no período de 2011 a 2014
PS_4km_2015_2018	Modelo com segmentos de extensão 4 km da Pista Sul, no período de 2015 a 2018
PS_500m_2011_2014	Modelo com segmentos de extensão 500 m da Pista Sul, no período de 2011 a 2014
PS_500m_2015_2018	Modelo com segmentos de extensão 500 m da Pista Sul, no período de 2015 a 2018
RNA	Redes neurais artificiais
RSL	Revisão Sistemática da Literatura

# 1. INTRODUÇÃO

O crescimento dos sistemas de transporte, especialmente o rodoviário, tem trazido consigo relevante aumento nos acidentes de trânsito. A segurança dos usuários do sistema (condutores, passageiros e pedestres) cada vez mais se constitui um dos objetivos principais do planejamento e operação desta modalidade de transporte (SINAY & TAMAYO, 2005).

É patente que a acidentalidade no trânsito é uma das grandes preocupações a nível mundial. Conforme estudo da Organização Mundial de Saúde (OMS), no ano de 2013 ocorreram 1,25 milhões de mortes por acidente de trânsito. Estes acidentes consomem mundialmente recursos de mais de 518 bilhões de dólares por ano.

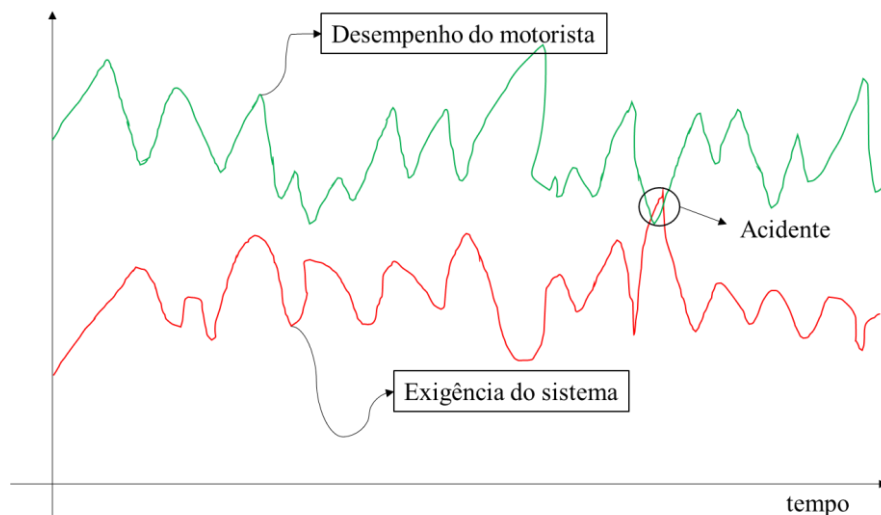
Em números absolutos, o Brasil está em terceiro lugar entre os países com maior número de mortes no trânsito, sendo que no ano de 2014 foram registradas no Brasil mais de 44 mil vítimas fatais (WHO, 2015). E, de acordo com o DATASUS (2017), este total de mortes apresenta uma tendência geral de crescimento.

Neste contexto, a abordagem de Sistemas Seguros tem ganhado força e compulsado cada vez mais esforços para o enfrentamento da problemática da segurança viária. Trata-se de uma abordagem sistêmica que integra os principais elementos de gerenciamento e áreas de ação para criar um sistema de mobilidade seguro. De acordo com ITF (2008) e WRI (2018), este é o único caminho para alcançar zero fatalidades ou lesões graves decorrentes de acidentes de trânsito, objetivo central da estratégia correlata Visão Zero.

Conforme ITF (2016), um Sistema Seguro baseia-se em quatro princípios fundamentais: as pessoas, inevitavelmente, cometem erros que levam a ocorrência de acidentes; o corpo humano tem capacidade física limitada para tolerar forças de impacto; a mobilidade segura é uma responsabilidade compartilhada entre todas as partes interessadas; e todos os componentes do sistema devem ser fortalecidos para multiplicar o impacto das intervenções e fornecer segurança quando qualquer parte do sistema estiver deficiente.

Uma definição gráfica adequada para acidente de trânsito está apresentada na Figura 1.1, em que o sistema requer certo nível de desempenho do condutor e, quando este não performa consoante a exigência, ocorre o acidente. Deste modo, na medida em que os seres humanos

cometem falhas, os projetistas de infraestrutura viária devem prover um sistema de transporte que minimize as consequências do erro humano. Para tanto, é essencial a investigação da ocorrência dos acidentes de trânsito, onde a Modelagem da Segurança Viária (MSV) traz grande contribuição (CHANG, 2005; KIM & WASHINGTON, 2006; LORD & MANNERING, 2010; CAFISO *et al.*, 2010; COSTA, 2013).



**Figura 1.1** - Definição gráfica de acidente de trânsito

Fonte: Nodari (2016)

Lord e Mannering (2010) reiteram que pesquisadores têm se dedicado à investigação dos fatores que afetam o número de acidentes que ocorre em algum espaço geográfico – normalmente uma interseção ou segmento de via – durante um período de tempo especificado, o que resulta em dados de frequência de acidentes e/ou severidade destes, objetivo dos Modelos de Previsão de Acidentes (MPA).

Um desafio inicial na previsão de frequência de acidentes é a estratégia adotada para segmentação da rodovia, especialmente quanto a extensão do segmento. Diante da não obviedade da escolha, a definição desta extensão, na maioria das vezes, é condicionada pelos atributos escolhidos e pelo foco da análise de segurança. Tal fato requer atenção e sinaliza para a necessidade de investigação da influência da extensão do segmento no processo de modelagem (COOK *et al.*, 2011; GREEN & AGENT, 2011; BORSOS *et al.*, 2014; GREEN *et al.*, 2017; CAFISO *et al.*, 2018).

A maioria desses estudos têm foco em acidentes gerais ou número total de acidentes, em contraposição aos poucos estudos que têm se dedicado a modelagem de diferentes tipos de



acidentes. No entanto, diversas análises de acidentes de trânsito transcendem uma resposta unitária, como o caso da frequência por tipo de severidade. Nestes casos, de um lado, pesquisadores consideram uma abordagem de duas etapas: um modelo para previsão da frequência total de acidentes e outro modelo probabilístico condicional para previsão da severidade. Doutra lado, são essencialmente desenvolvidos modelos de resposta univariada, ou seja, a frequência de acidentes para cada nível de severidade é estimada separadamente (MA *et al.*, 2008; EL-BASYOUNY & SAYED, 2009; CHENG *et al.*, 2017).

Frente a tais limitações, a abordagem de resposta multivariada tem ganhado força. Tais modelos de previsão multivariada de frequência de acidentes considera a interdependência no número de acidentes em diferentes níveis de severidade para um segmento rodoviário (LORD & MANNERING, 2010). Quando comparados os resultados, demonstraram a superioridade da abordagem de resposta multivariada frente aos modelos de uma variável-resposta, conforme afirmam El-Basyouny e Sayed (2009), Lee *et al.* (2015), Jonathan *et al.* (2016) e Ma *et al.* (2017).

A modelagem da segurança viária é tradicionalmente estatística, no entanto, pesquisadores destacam que este tipo de modelagem requer suposição sobre a distribuição dos dados e ainda, estabelece *a priori* a forma funcional entre variáveis dependentes e explicativas (MUSSONE *et al.*, 1999; CHANG, 2005; LI *et al.*, 2012).

Como afirmam os autores supracitados, o uso de Redes Neurais Artificiais (RNA) não requer este tipo de relação pré-definida entre as variáveis e em vez de elaborar uma forma funcional analítica, tarefa bastante complexa e laboriosa, é construído um modelo, a partir do aprendizado dos dados reais de acidentes, com os pesos empregados para cada variável. Hashemi *et al.* (1995) destacam que a RNA é capaz de determinar uma relação entre os dados, enquanto a regressão requer conhecimento da natureza do relacionamento subjacente.

A robustez é a principal vantagem da utilização de RNA – ou outra técnica similar de Aprendizado de Máquina (AM) – e está na sua capacidade de reconhecimento de padrões para detecção do relacionamento (linear ou não-linear) entre as variáveis. Tal aspecto que, conforme Abdelwahab e Abdel-Aty (2001), pode levar a uma maior compreensão da relação entre os fatores contribuintes e a ocorrência de acidentes.

Além disso, Mannering e Bhat (2014) apontaram para a necessidade de exploração de modelos multivariados, mediante exploração de abordagens alternativas sugerindo, nomeadamente, a utilização de aprendizado de máquina.

Destaca-se, outrossim, que são escassos os estudos de MPA em rodovias de pista dupla, especialmente no Brasil, em contraposição ao importante papel deste tipo de via na logística rodoviária brasileira (WAIHRICH, 2016).

Assim, nota-se que, mesmo diante da constante evolução na modelagem da segurança viária, algumas importantes questões identificadas na literatura merecem exploração aprofundada e constituem-se como valiosas oportunidades de investigação. Compreender melhor tais aspectos contribuirá para o entendimento e descoberta de padrões entre fatores contribuintes e acidentes de trânsito em rodovias de pista dupla segundo os diferentes níveis de severidade, tendo ainda em atenção à influência da extensão do segmento e o uso potencial de técnicas alternativas de AM.

## **1.1. PROBLEMA E QUESTÕES DE PESQUISA**

Diante da contextualização apresentada, o problema da pesquisa está associado à necessidade de compreender melhor os fatores contribuintes para ocorrência de acidentes em rodovias de pista dupla, segundo os diferentes níveis de severidade. Para além disso, mostra-se relevante a exploração de técnicas alternativas para tal finalidade, uma vez que a modelagem estatística da segurança viária, embora de grande utilidade, requer suposição sobre a distribuição dos dados e definição *a priori* da forma funcional do modelo. Porém, muitas vezes essas premissas podem não ser verdadeiras, e em sendo violadas, conduzem a estimativas e inferências equivocadas.

Posto isto, as seguintes questões de pesquisa são definidas:

1. O emprego de técnica de Aprendizado de Máquina tem uso potencial na modelagem da segurança viária?
2. Qual a influência da extensão do segmento na modelagem?
3. Os modelos desenvolvidos possibilitam a interpretação dos efeitos das variáveis?
4. Os resultados obtidos dos modelos são úteis para identificação de segmentos críticos?

## **1.2. OBJETIVOS**

O objetivo geral da pesquisa é desenvolver modelos de previsão de frequência de acidentes por severidade em rodovia brasileira de pista dupla com uso de técnicas de Aprendizado de Máquina. Para além do objetivo geral, ainda se constituem por objetivos específicos:

- Investigar a adequação do uso de técnica de AM para previsão multivariada de acidentes;
- Avaliar a influência da extensão do segmento no processo de modelagem;
- Avaliar a interpretabilidade dos modelos quanto aos efeitos das variáveis; e
- Investigar a aplicabilidade dos modelos desenvolvidos para ranqueamento e identificação de segmentos críticos.

## **1.3. ESTRUTURA**

Esta tese de doutorado está estruturada em oito capítulos, os quais estão esquematicamente apresentados na Figura 1.2. O Capítulo 1 é introdutório e destaca o contexto da pesquisa, caracterização do problema, justificativa e objetivos.

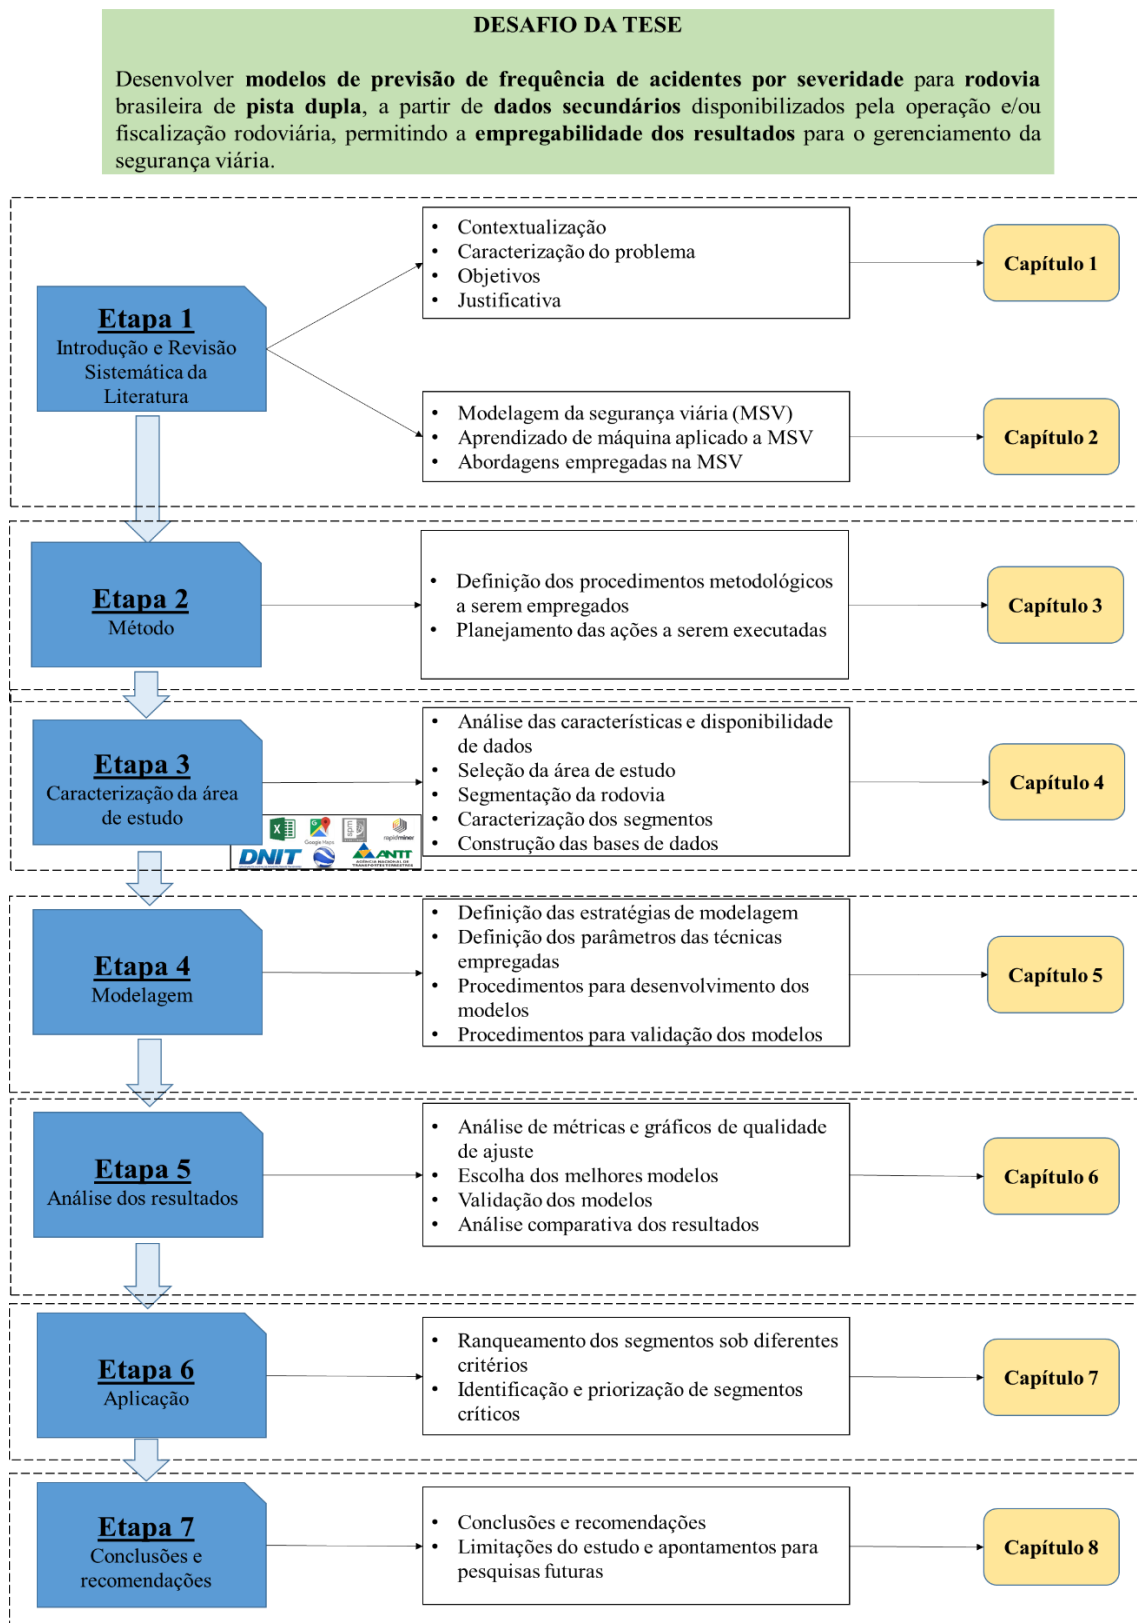
No Capítulo 2 está apresentada a revisão da literatura que aborda a modelagem da segurança viária, especialmente com uso de aprendizado de máquina. São destacados os aspectos mais importantes no processo de modelagem e que foram empregados no desenvolvimento da presente pesquisa.

O Capítulo 3 traz o detalhamento das etapas metodológicas da pesquisa. No Capítulo 4 tem-se a descrição da informação integrada na base de dados e, no Capítulo 5, são apresentados os detalhes dos procedimentos empregados na modelagem e validação dos modelos desenvolvidos.

O Capítulo 6 é o mais robusto, contemplando os resultados de ajuste dos modelos e respectivos procedimentos de validação. As discussões e constatações relativas a cada abordagem são apresentadas também neste capítulo.

No Capítulo 7 está demonstrada a aplicabilidade dos resultados dos modelos desenvolvidos para ranqueamento e identificação de segmentos críticos. Por fim, o Capítulo 8 se presta a

apresentar as principais conclusões do trabalho, bem como limitações da pesquisa e sugestões para trabalhos posteriores.



**Figura 1.2-** Estrutura da tese

## 2. MODELAGEM DA SEGURANÇA VIÁRIA

Os modelos de previsão de acidentes são bastante úteis para a compreensão e promoção da segurança viária, sendo subsídio para investigação e proposição de contramedidas. Wang *et al.* (2011) afirmam que os Modelos de Previsão de Acidentes (MPA) são amplamente utilizados para a estimativa de frequência de acidentes para uma determinada unidade espacial, em um determinado período de tempo. No mesmo alinhamento, Savolainen *et al.* (2011) destacam a importância de modelos de previsão de acidentes por gravidade de lesão, dada sua utilidade na proposição de contramedidas que visem a redução da severidade dos acidentes. Kim e Washington (2006) e Hauer (2004) explicitam que a modelagem da segurança viária pode fornecer dois resultados: a estimativa da frequência esperada de acidentes (ou acidentes por gravidade) de um elemento da infraestrutura com base nas suas características; e a estimativa da influência das características de um elemento da infraestrutura na frequência esperada de acidentes (ou na severidade dos acidentes). Este estudo tem foco no primeiro propósito.

A modelagem da segurança viária se propõe a ajustar um modelo aos dados de acidentes, características geométricas e operacionais de uma via (ou trecho dela) e condições ambientais. Portanto, os modelos buscam representar a realidade de forma simplificada, incorporando fatores tidos como importantes para sua descrição (HAUER, 2004; CHANG, 2005). Desta forma, as técnicas de modelagem são o meio de obtenção de modelos que reproduzam de forma mais fidedigna a realidade, sendo bastante importante o emprego de técnicas adequadas à natureza dos dados a serem tratados (COSTA, 2013).

Dados operacionais dos veículos (taxas de aceleração, de frenagem, velocidade, dentre outros) e dados dos condutores (resposta do motorista à estímulos, idade, padrão de infrações cometidas, dentre outros) associados com dados detalhados sobre acidentes, permitiriam a identificação mais precisa dos fatores associados à ocorrência de acidentes. No entanto, muitos destes dados são inexistentes, e outros não acessíveis por questões legais, tais como, proteção da privacidade individual. Ante ao exposto, pesquisadores têm estudado como e quais fatores influenciam no número e na gravidade de acidentes ocorridos em algum espaço físico geográfico (em geral, um segmento ou interseção), ao longo de um período de tempo especificado (semana, mês, ano(s)) (LORD & MANNERING, 2010). Por isso, são considerados os fatores viário-ambiental, humano e/ou veicular associados a falhas e, assegura-se que os dados estejam disponíveis para o desenvolvimento de MPA.

A análise dos acidentes quanto a severidade, como para previsão de frequência, pode ser conduzida por diferentes abordagens. Na análise de severidade a variável-resposta é a classificação do acidente, podendo ser um problema binário (ex.: lesão corporal ou danos materiais; ileso ou ferido; possível lesão/lesão não incapacitante ou lesão incapacitante/fatalidade) ou de multiclassificação (ex.: sem lesão, lesão ou fatalidade; sem lesão, possível lesão, lesão evidente ou lesão incapacitante/fatalidade; sem lesão, possível lesão, lesão evidente, lesão incapacitante ou fatalidade).

Os pesquisadores têm investigado a relação entre a severidade do acidente e os fatores de risco (fatores humanos, viário-ambientais e/ou veiculares), inclusive para tipos específicos de colisão (ex.: tombamento/capotagem) e veículos envolvidos (ex.: colisão entre dois veículos leves). Na análise dos acidentes por gravidade de lesão há investigações relacionadas à identificação da importância relativa das variáveis explicativas nas diferentes gravidades de lesão resultantes dos acidentes.

Nos modelos de previsão da frequência de acidentes, tem-se buscado estabelecer a relação entre o número de acidentes e os fatores de risco, basicamente os fatores viário-ambientais. A variável-resposta desses modelos é o número de acidentes por segmento ou o número de acidentes por segmento por ano. Um modelo de previsão de frequência dos acidentes permite avaliar os fatores contribuintes para a ocorrência do número total de acidentes. Por outro lado, os MPA são úteis para o entendimento dos fatores que contribuem para a severidade dos acidentes.

Destaca-se, entretanto, que no fenômeno em estudo, o acidente de trânsito, a frequência e severidade ocorrem simultaneamente, o que justifica a investigação conjunta destes dois aspectos. A abordagem conjunta permite a avaliação focada na redução do número de acidentes e ainda, segundo cada nível de severidade. As constatações advindas dessa abordagem, objetivo desta tese, são valiosas para a atuação de gestores da operação e fiscalização rodoviária.

## **2.1. MODELAGEM ESTATÍSTICA DA SEGURANÇA VIÁRIA**

Tradicionalmente têm sido empregadas técnicas de modelagem estatística para previsão de acidentes, valendo-se de modelos que são adequados às especificidades dos dados (CHANG,

2005). Hauer (2004) destaca que o elemento central da modelagem estatística da segurança viária é a equação do modelo, que genericamente assume a seguinte forma:

$$Y = f(X_1, X_2, X_3, \dots, X_n, \beta_1, \beta_2, \beta_3, \dots, \beta_n) \quad (2.1)$$

Em que  $Y$  denota o número esperado de acidentes por unidade de tempo para elementos com valores de características  $X_1, X_2, \dots, X_n$  quando os parâmetros são  $\beta_1, \beta_2, \dots, \beta_n$ . E, por fim, o  $f(\ )$  que representa a função empregada no modelo.

Estudos iniciais se centraram em utilizar Regressão Linear Múltipla para modelar os acidentes de trânsito. No entanto, o fenômeno em análise não satisfaz alguns pressupostos da técnica, nomeadamente a homocedasticidade (a variância do erro é igual para quaisquer valores da variável preditora), a existência de valores negativos da variável dependente e distribuição normal do erro (JOVANIS & CHANG, 1986; JOSHUA & GARBER, 1990; MIAOU & LUM, 1993; BOFFO, 2011).

Em geral, quando o fenômeno sob estudo não atendia à suposição de normalidade, algum tipo de transformação era sugerido para alcançar a normalidade procurada. Todavia, com o desenvolvimento computacional, a proposta mais interessante foi a de Nelder e Wedderburn (1972), os chamados Modelos Lineares Generalizados (MLG). Esses modelos caracterizam-se por uma componente aleatória distribuída segundo uma função da família exponencial, por uma componente sistemática e por uma função de ligação das referidas componentes. A ideia central é permitir mais opções para a distribuição da variável resposta, dentre as pertencentes à família exponencial, além de dar maior flexibilidade para a relação funcional entre a média da variável resposta e o preditor linear (PAULA, 2004). Dessa forma, os MLG surgem como uma importante alternativa no processo de modelagem da segurança viária.

Conforme destacado por Lord e Mannering (2010), os principais modelos utilizados para previsão de acidentes são: Regressão de Poisson, Regressão Binomial, Regressão Binomial Negativa, Regressão Poisson Lognormal, Regressão Gama, Regressão Inflacionada de Zero, Equações de Estimação Generalizadas, Modelo Multinomial Negativo, Modelo de efeitos aleatórios, Modelo de parâmetros aleatórios e Modelo Multivariado. Este último, por ser empregado nesta pesquisa para fins de comparação com os modelos de aprendizado de máquina, é detalhado no tópico 2.2.

## 2.2. MODELAGEM DA SEGURANÇA VIÁRIA COM MODELOS MULTIVARIADOS

Quando há o interesse na modelagem da frequência de acidentes, não apenas do total, mas da frequência de diferentes tipos de acidentes (número de acidentes sem vítimas, número de acidentes com vítimas, número de acidentes com fatalidades, etc.), faz-se necessário utilizar os Modelos Multivariados. Estes modelos consideram explicitamente a correlação entre as saídas (níveis de severidade, por exemplo) para cada elemento da rodovia (MIAOU & SONG, 2005; SONG *et al.*, 2006; EL-BASYOUNY & SAYED, 2009). Além disso, conforme afirmam Zhan *et al.* (2015), diferentes estudos desenvolvidos confirmaram que a abordagem multivariada fornece ajuste superior aos dados em comparação com os modelos univariados.

Assim, os modelos multivariados são adequados aos problemas de modelagem conjunta de mais de dois tipos de saídas (três tipos de acidentes, por exemplo). Dentre os propostos, destacam-se o modelo multivariado de Poisson (MA & KOCKELMAN, 2006), modelo multivariado Binomial Negativo (WINKELMAN, 2003), modelo misto multivariado Poisson gama (HAUSMAN *et al.*, 1984) e o modelo multivariado Poisson lognormal (PARK & LORD, 2007; MA *et al.*, 2008; EL-BASYOUNY & SAYED, 2009; LORD & MANNERING, 2010). Este último, superando os anteriores, é capaz de explicar os efeitos de correlação negativa e superdispersão nos níveis de severidade de cada observação.

Diversos estudos recentes têm empregado o modelo multivariado Poisson lognormal (MVPLN) (YE *et al.*, 2013; AGUERO-VALVERDE *et al.*, 2016; ZENG *et al.*, 2016b; WANG *et al.*, 2017; ZHAO *et al.*, 2018), que tem se mostrado adequado a este tipo de modelagem. Neste modelo, conforme Zeng *et al.* (2016b), para a modelagem conjunta de diferentes níveis de severidade, assume-se que o número de acidentes  $Y_{its}$  no local  $i$  durante o período  $t$  com o nível de severidade  $s$  segue a distribuição de Poisson, dado  $\lambda_{its}$ , da seguinte forma:

$$P(Y_{its} = y_{its} | \lambda_{its}) = \lambda_{its}^{y_{its}} \frac{e^{-\lambda_{its}}}{y_{its}!} \quad (2.2)$$

$$i = 1, 2, \dots, N, \quad t = 1, 2, \dots, T, \quad s = 1, 2, \dots, S, \quad y_{its} = 0, 1, 2, 3, \dots$$

Em que  $N$ ,  $T$ , e  $S$  correspondem ao número de locais observados, os períodos e nível de severidade, respectivamente.



A taxa média da distribuição de Poisson é modelada como uma função das covariáveis,  $X_{it}$ , seguindo uma distribuição lognormal, como apresentado na Equação 2.3.

$$\ln(\lambda_{its}) = \beta_{0s} + \mathbf{X}'_{it}\beta_s + \varepsilon_{its} \quad (2.3)$$

Em que  $\beta_{0s}$  é o intercepto para a severidade  $s$ ,  $\beta_s$  são os coeficientes a serem estimados para a severidade  $s$  para cada covariável  $X_{it}$  e, o termo de efeitos latentes,  $\varepsilon_{its}$ , acomoda a heterogeneidade individual não observada correlacionada entre os níveis de severidade, que segue uma distribuição normal multivariada (MN):

$$\varepsilon_{it} \sim MN(0, \Sigma) \quad \varepsilon_{it} = \begin{pmatrix} \varepsilon_{it1} \\ \varepsilon_{it2} \\ \dots \\ \varepsilon_{itS} \end{pmatrix} \quad \Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1S} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2S} \\ \dots & \dots & \dots & \dots \\ \sigma_{S1} & \sigma_{S2} & \dots & \sigma_{SS} \end{pmatrix} \quad (2.4)$$

Em que  $0$  é um vetor nulo  $S$ -dimensional, e  $\Sigma$  é uma matriz de variância-covariância de dimensão  $S \times S$ .

### 2.3. MODELAGEM DA SEGURANÇA VIÁRIA COM TÉCNICAS DE APRENDIZADO DE MÁQUINA

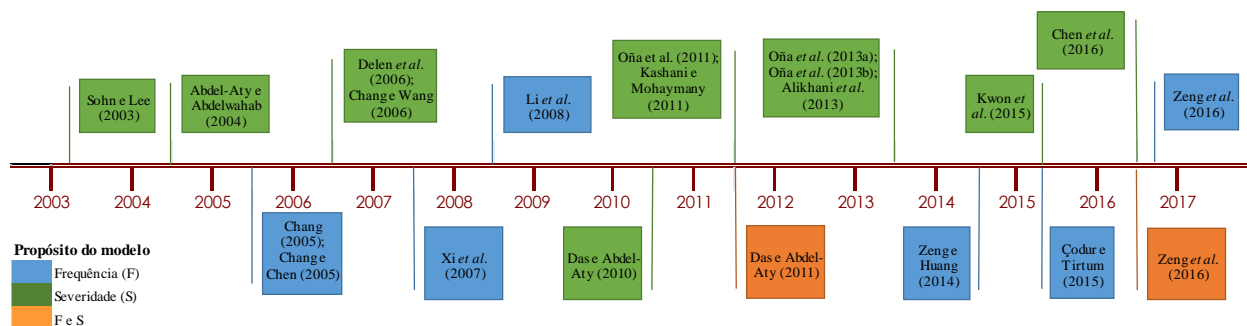
Lord e Mannering (2010) apresentam em seu trabalho a evolução da modelagem estatística ao longo dos anos, destacando-se o desenvolvimento de modelos com ajuste estatístico superior e melhores capacidades de predição. Ainda assim, no entanto, são reconhecidas as limitações neste tipo de abordagem, uma vez que cada modelo estatístico tem pressupostos próprios e relação pré-definida entre variáveis dependentes e independentes (ZENG *et al.*, 2016a).

Mussone *et al.* (1999), Li *et al.* (2012) e Chang (2005) destacam que a modelagem estatística requer suposição sobre a distribuição dos dados e ainda, estabelece uma forma funcional entre variáveis dependentes e explicativas. Diversas vezes essas premissas podem não ser verdadeiras, e em sendo violadas, conduzem a estimativas equivocadas e produção incorreta de inferências. Os autores, reiterados por Abdelwahab e Abdel-Aty (2001), evidenciam ainda que o uso de Redes Neurais Artificiais (RNA) não requer este tipo de relação pré-definida entre as variáveis. A técnica visa a construção do modelo a partir do aprendizado orientado por dados

reais de acidentes que resulta em uma estrutura de pesos e função de ativação funcionando de modo não linear, ou seja, não é elaborada uma forma funcional analítica representativa do fenômeno modelado.

Neste contexto, pesquisadores também têm envidado esforços para explorar a aplicabilidade de técnicas de Aprendizado de Máquina (AM) na modelagem da segurança viária. Tendo em vista que o presente trabalho está direcionado à análise de rodovias brasileiras de pista dupla, nesta seção são apresentados os trabalhos de modelagem da segurança viária em rodovias com uso de técnicas de AM, destacando-se as abordagens e características pertinentes de cada um.

A revisão de literatura foi executada de forma sistemática, com procedimento detalhado no Apêndice A. Os trabalhos selecionados foram analisados e suas informações organizadas e sistematizadas, de modo a permitir a ponderação quanto aos tipos de modelagens, objeto de estudo, dados de entrada, dados de saída, medidas de desempenho dos modelos, dentre outras características. Na Figura 2.1 está apresentada a linha cronológica de publicação dos artigos, identificados pelos autores e destacados, conforme a legenda de cores, quanto ao propósito da modelagem.



**Figura 2.1-** Linha do tempo dos artigos sistematizados

### 2.3.1. Abordagens Metodológicas

O Aprendizado de Máquina (AM), uma subárea da Inteligência Artificial, é bastante utilizado e se coloca como uma poderosa ferramenta para resolver problemas em vários domínios de aplicação. Os algoritmos de AM envolvem conhecimento de diferentes áreas, tais como Probabilidade e Estatística, Complexidade Computacional, Teoria da Informação, Psicologia, Neurobiologia e Teoria de Controle (MITCHELL, 1997; BASGALUPP, 2010).

A forma de aprendizagem ocorre, basicamente, de três formas distintas: supervisionado, não supervisionado e semi-supervisionado. No caso da aprendizagem supervisionada, os valores-resposta dos exemplos do conjunto de treinamento são conhecidos, ou seja, o objetivo é aprender um mapeamento de  $x$  para  $y$ , dado um conjunto de treinamento com os pares  $(x_i, y_i)$ . Nesta situação, é avaliada a resposta do modelo ao padrão atual dos *inputs*, permitindo alterações que levem a resposta do modelo a aproximar-se da resposta esperada (conhecida). Já no aprendizado não supervisionado, os dados são não rotulados (classes desconhecidas) e o objetivo é encontrar uma estrutura interessante (relações e padrões) nos dados  $(x_1, \dots, x_n)$  dos  $n$  exemplos. O caso semi-supervisionado é intermediário entre os dois anteriores; além de fornecer os dados não rotulados (sem resposta conhecida), são fornecidas algumas informações de supervisão – mas não necessariamente para todos os exemplos – (DECKER & FOCARDI, 1995; CHAPELLE *et al.*, 2006).

O caso em tela, ou seja, a modelagem da segurança viária é passível de ser realizada mediante o aprendizado supervisionado, pois esse fenômeno pode ser representado em uma base de dados com valores de saída conhecidos, como a frequência ou severidade de acidentes.

Sendo um conjunto de dados de entrada descritos por pares  $(x_i, y)$ , em que  $x_i = (x_1, x_2, \dots, x_n)$  é o vetor de variáveis que representa os atributos preditivos, e  $y$  é o rótulo da classe à qual esse exemplo pertence, a tarefa é aprender uma função alvo  $f$  que mapeia cada conjunto de atributos  $x$  a uma das  $y$  classes pré-definidas (TAN *et al.*, 2005). A classe (rótulo) é um atributo especial que descreve uma instância do fenômeno de interesse, sendo um problema de regressão caso seja contínuo, ou problema de classificação, caso a classe seja discreta (CHAPELLE *et al.*, 2006). Na Tabela 2.1 estão apresentados os trabalhos identificados na Revisão Sistemática de Literatura, consoante o tipo de técnica empregada e características gerais.

**Tabela 2.1** - Descrição geral dos artigos sistematizados

Referência	Variáveis dependentes	Técnica(s) utilizada(s)	Dados (período)	Área de estudo	
<b>Sohn e Lee (2003)</b>	<i>Classificação</i> #lesão corporal; #danos materiais	RNA; AD	11.564 acidentes (1 ano)	Vias urbanas	
<b>Abdel-Aty e Abdelwahab (2004)</b>	<i>Classificação</i> #sem lesão; #possível lesão; #lesão evidente; #lesão incapacitante/fatalidade	RNA	7.891 acidentes (2 anos)	Vias urbanas e rodovias	
<b>Chang (2005)</b>	<i>Frequência</i> #Nº de acidentes/segmento/ano	RNA	1.338 acidentes (2 anos)	Rodovia de pista dupla	996 segmentos (entre 0,1 km e 4,2 km)
<b>Chang e Chen (2005)</b>	<i>Frequência</i> #Nº de acidentes/segmento/ano	CART	1.075 acidentes (2 anos)	Rodovias de pista dupla	742 segmentos de 1 km
<b>Delen et al. (2006)</b>	<i>Classificação</i> #sem lesão; #possível lesão; #lesão não incapacitante; #lesão incapacitante; #fatalidade	RNA	30.358 acidentes (6 anos)	Vias urbanas e rodovias	
<b>Chang e Wang (2006)</b>	<i>Classificação</i> #sem lesão; #lesão; #fatalidade	CART	12.604 acidentes (1 ano)	Vias urbanas e rodovias	
<b>Xie et al. (2007)</b>	<i>Frequência</i> #Nº de acidentes/segmento	RNA	122 acidentes (5 anos)	Rodovias de pista simples	88 segmentos (entre 1,11 km e 8,59 km)
<b>Li et al. (2008)</b>	<i>Frequência</i> #Nº de acidentes/segmento	SVM	122 acidentes (5 anos)	Rodovias de pista simples	88 segmentos (entre 1,11 km e 8,59 km)
<b>Das e Abdel-Aty (2010)</b>	<i>Classificação</i> #sem lesão; #possível lesão/lesão não incapacitante; #lesão incapacitante/fatalidade	PG	104.952 acidentes (3 anos)	Vias expressas	
<b>Oña et al. (2011)</b>	<i>Classificação</i> #lesão leve; #lesão grave/fatalidade	RB	1.536 acidentes (3 anos)	Rodovias de pista simples	
<b>Kashani e Mohaymany (2011)</b>	<i>Classificação</i> #lesão leve; #lesão grave; #fatalidade	CART	21.025 acidentes (3 anos)	Rodovias de pista simples	

**LEGENDA**

AD: Árvores de decisão      ANFIS: Sistema *neuro-fuzzy*      CART: Árvores de classificação e regressão      PG: Programação genética  
 RB: Redes Bayesianas      RNA: Redes neurais artificiais      SVM: Máquina de vetores de suporte

Referência	Variáveis dependentes	Técnica(s) utilizada(s)	Dados (período)	Área de estudo
<b>Das e Abdel-Aty (2011)</b>	<i>Classificação</i> #possível lesão/lesão não incapacitante; #lesão incapacitante/fatalidade <i>Frequência</i> #Nº de acidentes/segmento	PG	57.155 acidentes (3 anos)	Vias urbanas Segmentos de 850 m
<b>Oña et al. (2013a)</b>	<i>Classificação</i> #lesão leve; #lesão grave/fatalidade	CART; AD	1.801 acidentes (7 anos)	Rodovias de pista simples
<b>Oña et al. (2013b)</b>	<i>Classificação</i> #lesão leve; #lesão grave/fatalidade	RB	3.229 acidentes (4 anos)	Rodovias de pista simples
<b>Alikhani et al. (2013)</b>	<i>Classificação</i> #lesão corporal; #danos materiais	RNA; ANFIS	7.035 acidentes (1 ano)	Rodovias
<b>Zeng e Huang (2014)</b>	<i>Classificação</i> #sem lesão/danos materiais; #possível lesão; #lesão não incapacitante; #lesão incapacitante/fatalidade	RNA	53.732 acidentes (1 ano)	Rodovias
<b>Kwon et al. (2015)</b>	<i>Classificação</i> #danos materiais; #fatalidade	AD	1.350.958 acidentes (7 anos)	Rodovias
<b>Çodur e Tortum (2015)</b>	<i>Frequência</i> #Nº de acidentes/segmento	RNA	7.285 acidentes (8 anos)	Rodovias de pista dupla 16 segmentos (entre 4 km e 18,4 km)
<b>Chen et al. (2016)</b>	<i>Classificação</i> #sem lesão; #lesão não incapacitante; #lesão incapacitante/fatalidade	CART; SVM	3.106 acidentes (2 anos)	Vias urbanas e rodovias
<b>Zeng et al. (2016a)</b>	<i>Frequência</i> #Nº de acidentes/segmento/ano	RNA	1.612 acidentes (5 anos)	Rodovias 211 segmentos (entre 0,15 km e 9,07 km)
<b>Zeng et al. (2016b)</b>	<i>Frequência por severidade</i> #Nº de acidentes com lesões leves/segmento/ano; #Nº de acidentes com lesões graves ou fatalidades/segmento/ano	RNA	1.612 acidentes (5 anos)	Rodovias 211 segmentos (entre 0,15 km e 9,07 km)

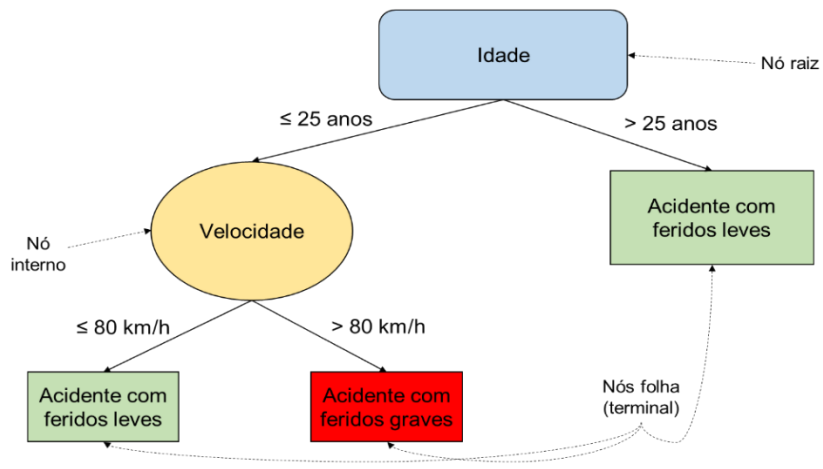
#### LEGENDA

AD: Árvores de decisão    ANFIS: Sistema *neuro-fuzzy*    CART: Árvores de classificação e regressão    PG: Programação genética  
 RB: Redes Bayesianas    RNA: Redes neurais artificiais    SVM: Máquina de vetores de suporte

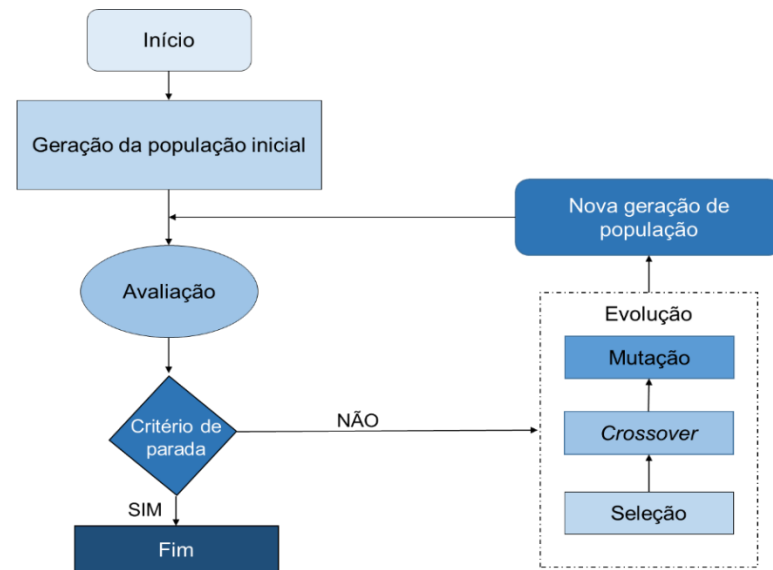
Os grandes grupos de técnicas identificadas para a tarefa de modelagem da segurança viária, foram: Árvores de Decisão, Algoritmos Evolutivos, Máquinas de Suporte de Vetor e Redes Neurais Artificiais, cujas ilustrações constam nas Figuras 2.2 e 2.3.

O uso de Árvores de Decisão (AD) é bastante útil nas tarefas de classificação. Na construção de AD é utilizado um conjunto de treinamento formado pelas entradas e saídas, sendo essas últimas as classes. A estrutura de uma AD contém um nó raiz (que inicia a árvore), nós de decisão (que dividem um determinado atributo e geram as ramificações) e folhas (que contém as informações de classificação). Cada nó indica o teste de um atributo, sendo a utilidade do atributo para a classificação utilizada como critério de ramificação. Dessa forma, o atributo escolhido, que será um nó da árvore, é aquele que gera maior ganho de informação (entropia), ou seja, melhor qualidade de classificação. Note-se que um percurso na árvore (da raiz à cada nó-folha) corresponde a uma regra de associação (QUINLAN, 1986; TRABELSI *et al.*, 2019). Os algoritmos de indução de árvores de decisão buscam, em meio a um conjunto de atributos, aqueles que separam os exemplos da melhor forma, gerando sub-árvores. Os algoritmos de indução de árvores de decisão mais utilizados são ID3, C4.5 e CART. O primeiro, tem em conta o Ganho de Informação (GI) como medida de divisão da árvore; o segundo, é capaz de lidar com atributos numéricos e categóricos e utiliza uma medida de ganho relativa; por fim, o algoritmo *Classification and Regression Trees* (Árvores de Classificação e Regressão, em português), estende a técnica para aplicação em problemas de regressão.

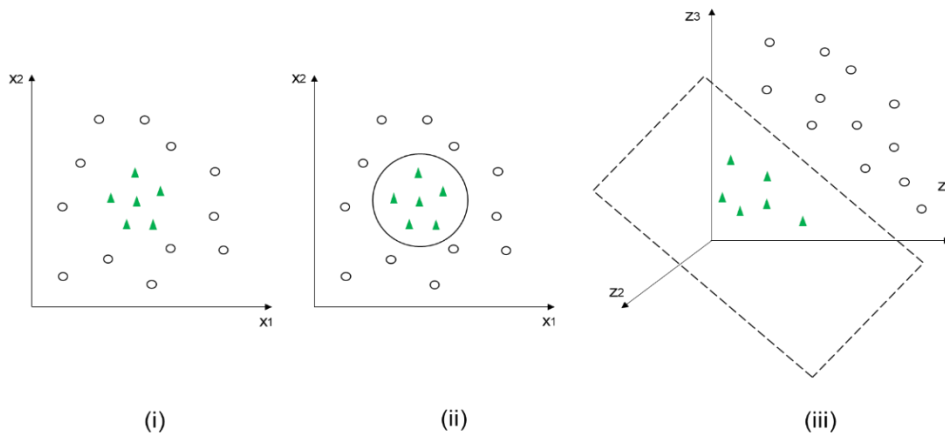
Algoritmos Evolutivos (AE) são métodos estocásticos de busca baseado nos mecanismos de seleção natural em que os indivíduos mais aptos sobrevivem (HOLLAND, 1975). Cada indivíduo corresponde a uma solução candidata para um determinado problema e é avaliado por uma função *fitness* (que mensura a qualidade da solução). A cada geração (iteração), os melhores indivíduos têm maior probabilidade de serem escolhidos para se reproduzirem. Os indivíduos selecionados sofrem operações de *crossover* (partes do material genético de dois indivíduos são trocados) e mutação (parte do material genético de um indivíduo é substituída por material genético formado aleatoriamente), gerando novos indivíduos (filhos) que irão substituir os pais e formar uma nova geração de população. O processo descrito é iterativo e se repete até que um critério de parada seja satisfeito (FLOREANO & MATTIUSSI, 2008; YU & GEN, 2010; MARTINO, 2015). Os dois tipos principais de AE são os Algoritmos Genéticos (AG) e a Programação Genética (PG), os quais são utilizados especialmente em problemas de otimização, e em muitos casos, associados a outras técnicas.



(a) Exemplo de árvore de decisão  
Adaptado de Abellán *et al.* (2013)



(b) Fluxograma t pico de algoritmos evolutivos  
Adaptado de Das e Abdel-Aty (2010)



(c) Exemplo de funcionamento de SVM para dados linearmente insepar veis  
Adaptado de Lee e Park (2011)

**Figura 2.2 - Ilustra o dos processos de Aprendizagem de M quina**

A técnica de Máquinas de Vetores de Suporte (SVM) – do inglês *Support Vector Machine* – é fundamentada na teoria do aprendizado estatístico (SCHOLKOPF & SMOLA, 2002). A ideia principal é construir um hiperplano como superfície de decisão, de forma que a margem de separação entre exemplos positivos e negativos seja máxima. O modelo discrimina, usando o hiperplano, o conjunto de amostras de teste dividindo-os em dois grupos: amostras negativas e amostras positivas. Apesar de concebida como técnica de classificação, também foi estendida para resolver problemas de regressão de dados não linearmente separáveis (BURGES, 1998; BORIN, 2007; MARETTO, 2011; ALVES, 2012).

As Redes Neurais Artificiais (RNA), por terem sido adotadas como abordagem metodológica da presente pesquisa, serão detalhadas no subitem 2.3.2. Após análise da literatura e avaliação exploratória das técnicas de AM (vide Apêndice B), optou-se seguramente pelas RNA uma vez que é descrita como uma técnica robusta, flexível e, para alguns casos, passível de interpretabilidade. Esses atributos são requisitos essenciais para a modelagem proposta nesta tese. Por fim, o uso das redes neurais permite o desenvolvimento de modelos de previsão de frequência de acidentes por severidade, ou seja, a regressão multivariada, que é objetivo principal da tese. Os detalhes acerca dos aspectos metodológicos do emprego de RNA e MVPLN estão apresentados no Capítulo 5.

### **2.3.2. Redes Neurais Artificiais**

Redes neurais artificiais (RNA) são inspiradas na estrutura neural de organismos inteligentes e que adquirem conhecimento por meio da experiência. Devido a sua inspiração biológica que foi estruturada como processamento paralelo de operações simplificadas, as RNA são capazes de modelar funções não-lineares complexas. Formalmente, uma rede neural pode ser entendida como um processador altamente complexo, não-linear e paralelo, que tem uma propensão natural de armazenar conhecimento experimental e torná-lo disponível posteriormente. Desta forma, por meio dos processos de aprendizagem, uma rede neural pode prever resultados ou reconhecer padrões para novos cenários do problema para o qual foi previamente treinada (HAYKIN, 1999).



### (i) Arquitetura e treinamento das RNA

Uma RNA é composta por unidades de processamento simples (neurônios) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede.

Para lidar com problemas não-lineares faz-se necessário o emprego de redes com múltiplas camadas (*multi layer perceptron* – MLP). Uma RNA é tipicamente composta por três tipos de camadas: uma camada de entrada, uma camada de saída e uma ou mais camadas ocultas.

A camada de entrada recebe os valores das variáveis explanatórias, que neste caso são os dados de acidentes, características viário-ambientais, veiculares e humanas. A camada oculta, composta por  $m$  neurônios, sumariza o peso dos valores de entrada das diferentes variáveis explanatórias e calcula os complicados padrões de associação.

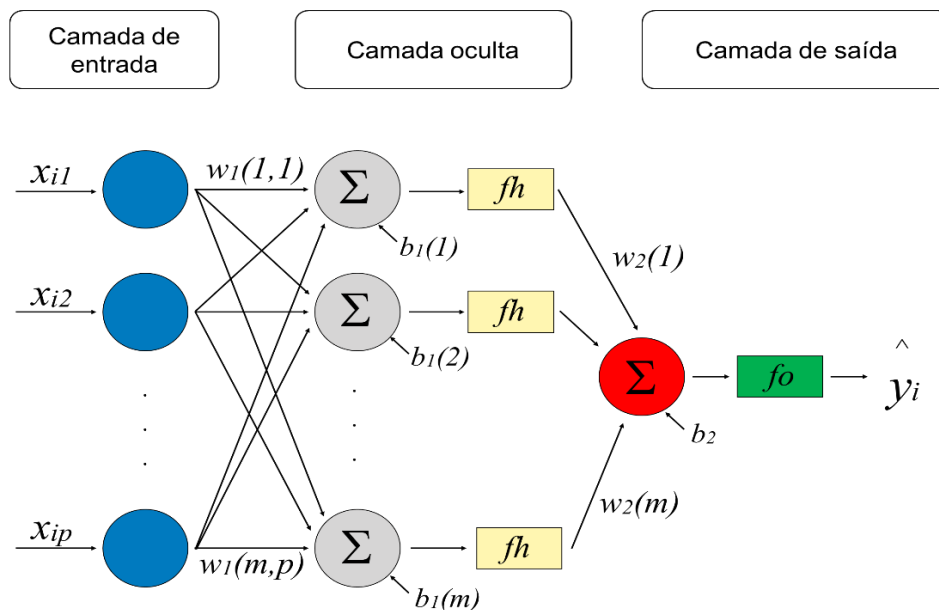
Geralmente apenas uma camada oculta é adequada para as aplicações na análise de acidentes, ao passo que a definição do número de neurônios nesta camada é geralmente alvo de experimentação (VILLIERS & BARNARD, 1993; CHANG, 2005). Já a camada de saída, soma os valores dos diferentes neurônios ocultos e, na sequência, apresenta os valores de saída da rede. Note-se que  $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$  é o conjunto de dados de acidentes utilizado. Na Figura 2.3 está apresentada a estrutura típica de uma RNA.

Dessa figura, considerando a função de transferência para a camada oculta,  $fh$ , do tipo tangente hiperbólica e uma função linear como função de transferência para a camada de saída,  $fo$ , o resultado de predição  $\hat{y}_i$ , é dado pela Equação 2.5.

$$\hat{y}_i = f(x_i, \varphi) = b_2 + \sum_{j=1}^m \left\{ w_2(j) \tanh \left( \sum_{k=1}^p w_1(j, k) x_{ik} + b_1(j) \right) \right\} \quad (2.5)$$

Em que  $p$  é o número de neurônios de entrada,  $m$  é o número de neurônios ocultos,  $b_1(j)$  e  $b_2$  são as *bias*,  $w_1(j, k)$  são os pesos das conexões entre a camada de entrada e a camada oculta,  $w_2(j)$  são os pesos das conexões entre a camada oculta e a camada de saída,  $x_{ik}$  o  $k$ -ésimo elemento

do  $i$ -ésimo input,  $x_i = [x_{i1}, \dots, x_{ik}, \dots, x_{ip}]$ ,  $\varphi$  é o vetor que contém todos os parâmetros da rede ( $b_1(j)$ ,  $b_2$ ,  $w_1(j, k)$  e  $w_2(j)$ ),  $i = 1, 2, \dots, n$ ;  $j = 1, 2, \dots, m$ ;  $k = 1, 2, \dots, p$ .



**Figura 2.3** - Estrutura típica de uma RNA feedforward com três camadas  
Fonte: Xi *et al.* (2007) adaptado

Para o caso de modelos de previsão de frequência de acidentes totais, existe um neurônio na camada de saída ( $\hat{y}_{i1}$ ) enquanto que, nos modelos de classificação de acidentes por severidade o número de saídas corresponderá ao número de classes de severidade considerados. Em um problema com as opções de classificação: sem vítimas, com vítimas, com vítimas fatais tem-se três saídas ( $\hat{y}_{i1}$ ,  $\hat{y}_{i2}$  e  $\hat{y}_{i3}$ ).

Quanto ao tipo de aprendizado, as RNA podem ser treinadas de duas formas: supervisionada ou não supervisionada. O aprendizado não supervisionado é aplicado para os casos em que as amostras não têm saídas conhecidas ou saídas esperadas. Já o aprendizado supervisionado ocorre nos casos em que as bases de dados trazem as respostas associadas a cada conjunto de variável de entrada. Este último caso é o que ocorre com os dados de acidentes de trânsito.

As redes podem ser classificadas, quanto à sua arquitetura, em *feedforward* ou recorrentes. O tipo *feedforward* (Figura 2.3), mais comum e mais utilizado, é caracterizado pela propagação dos sinais sempre das camadas anteriores para as posteriores ao passo que, as redes recorrentes

possuem, ao menos, um laço realimentando a saída de neurônios para outros neurônios da rede. Embora existam outras abordagens com arquitetura *feedforward*, tais como redes com função de base radial (*Radial Basis Function - RBF*), MLP é o mais popular tipo de rede supervisionada, tido como um aproximador universal e robusto para problemas de previsão e classificação. Ele é também, o mais utilizado para análise de dados de acidentes.

De todos os trabalhos de modelagem de segurança viária em rodovias identificados com uso de RNA (SOHN & LEE, 2003; ABDEL-ATY & ABDELWAHAB, 2004; CHANG, 2005; DELEN *et al.*, 2006; XIE *et al.*, 2007; ALIKHANI *et al.*, 2013; ZENG & HUANG, 2014; ÇODUR & TORTUM, 2015; HUANG *et al.*, 2016; ZENG *et al.*, 2016a; ZENG *et al.*, 2016b) apenas Huang *et al.* (2016) utilizaram arquitetura diferente de MLP, tendo empregado rede com função de base radial e desenvolveu um algoritmo de otimização (Tabela 2.2).

Em termos de treinamento de redes neurais de múltiplas camadas, o algoritmo mais comum e utilizado é o de retropropagação de erro (BP, do inglês *Backpropagation Algorithm*). Conforme Braga *et al.* (2011), na fase *forward* tem-se a propagação dos sinais de entrada ao longo da rede até a obtenção das saídas; na fase *backward*, é calculado o valor da função de custo na última camada, que é utilizado para recursivamente atualizar os pesos da rede até que previsões otimizadas sejam obtidas.

O algoritmo BP é geralmente baseado no método de gradiente descendente. O gradiente de uma função está na direção e sentido em que a função tem taxa de variação mínima. Desta forma, garante-se que a rede caminha na superfície na direção que leva à maior redução do erro (BOTERO, 2018). Chang (2005), Delen *et al.* (2006), Xi *et al.* (2007), Alikhani *et al.* (2013) e Çodur e Tortum (2015) utilizaram este algoritmo, ao passo que, Zeng e Huang (2014), Zeng *et al.* (2016a) e Zeng *et al.* (2016b) utilizaram algoritmos adaptados. Huang *et al.* (2016), por sua vez, procedeu ao treinamento das RBF por meio do algoritmo dos mínimos quadrados recursivo.

Outro elemento importante no aprendizado das RNA é a função de ativação. Ela está relacionada à capacidade representativa das redes neurais e introduz uma componente não linear. Transforma não linearmente o sinal de entrada, e a saída transformada é enviada para a próxima camada de neurônios como entrada. Assim, relaciona-se à decisão de ativar ou não o neurônio com base na informação recebida.

As principais funções de ativação identificadas nos trabalhos são a tangente hiperbólica (*tanh*)  $f(x) = (e^x - e^{-x}) / (e^x + e^{-x})$  e *sigmoidal* (*sigm*)  $f(x) = 1 / (1 + e^{-x})$ . Delen *et al.* (2006), Alikhani *et al.* (2013) e Çodur e Tortum (2015) utilizaram a função sigmoide logística, enquanto que Xie *et al.* (2007), Zeng *et al.* (2016a) e Zeng *et al.* (2016b) recorreram à função tangente hiperbólica. Zeng e Huang (2014) utilizaram nas redes treinadas com *backpropagation* a função de ativação sigmoide e nas redes treinadas com algoritmo de combinação convexa a função tangente hiperbólica. No trabalho de Huang *et al.* (2016), a função de ativação Gaussiana foi utilizada em todas as redes RBF.

**Tabela 2.2** - Resumo das características das RNA para modelagem da segurança viária

Autor	Arquitetura	Treinamento	Função de Ativação
Sohn e Lee, 2003	MLP	*	*
Abdel-Aty e Abdelwahab, 2004	MLP	*	*
Chang, 2005	MLP	BP	*
Delen <i>et al.</i> , 2006	MLP	BP	Sigmoide
Xi <i>et al.</i> , 2007	MLP	BP	Tangente Hiperbólica
Alikhani <i>et al.</i> , 2013	MLP	BP	Sigmóide
Zeng e Huang, 2014	MLP	BP e ACC	Sigmoide e tangente hiperbólica
Çodur e Tortum, 2015	MLP	BP	Sigmóide
Zeng <i>et al.</i> , 2016a	MLP	BP'	Tangente Hiperbólica
Zeng <i>et al.</i> , 2016b	MLP	BP'	Tangente Hiperbólica
Huang <i>et al.</i> , 2016	RBF	MQR	Gaussiana

**Nota:** ACC - algoritmo de combinação convexa; BP – *Backpropagation*; BP' – *Backpropagation* adaptado; MLP – *Multi Layer Perceptron*; MQR - Mínimos Quadrados Recursivos; RBF – Rede de Base Radial; \* parâmetro não referido no trabalho.

## (ii) Avaliação do desempenho das RNA

- *Avaliação da Validade Replicativa e Validade Preditiva*

Em se tratando de desempenho, os modelos baseados em técnicas de AM apresentaram, de forma geral, melhor performance em relação aos modelos estatísticos, quando houve comparação. Chang (2005) obteve 64% de acurácia no treinamento e 61,4% na validação com RNA, valores superiores ao modelo de regressão estatística com distribuição binomial negativa (58,3% e 60,8%). Xi *et al.* (2007) também evidenciaram melhores resultados com uso de RNA quando comparados aos modelos de regressão, por meio de métricas de erro.

Em Çodur e Tortum (2015), foram obtidos modelos de RNA com elevados valores de coeficiente de correlação e diminutos valores de erros. Zeng *et al.* (2016a) auferiram MAD (erro médio absoluto) igual a 3,437 na validação do modelo RNA otimizado, em contraste ao

MAD = 3,702 do modelo estatístico alvo de comparação. Zeng *et al.* (2016b) também constataram melhores resultados com uso de RNA do que com modelo multivariado Poisson lognormal. Os demais trabalhos, em que não houve comparação com técnicas estatísticas, têm suas medidas de desempenho detalhadas no Apêndice A.

- *Avaliação da validade estrutural*

Um aspecto criticado nas RNA é o fato destas serem tidas como “caixas-preta”, ou seja, é um sistema sub simbólico que produz resultados de forma implícita (processamento fechado), sem revelar, por meio de gráficos, equações ou conjunto de regras, o mapeamento entre as variáveis. No entanto, em resposta a esta limitação, pesquisadores vem desenvolvendo métodos capazes de dar maior interpretabilidade aos resultados dos modelos. A análise de sensibilidade é um destes métodos que busca delinear o relacionamento entre os *inputs* e *outputs* de uma rede treinada. Este tornou-se um método comumente utilizado para identificar a influência de cada variável independente sobre as variáveis dependentes (variáveis de saída). Em termos gerais, o processo consiste em perturbar as variáveis de entrada e relatar a correspondente mudança, como por exemplo, o desvio percentual na saída. O resultado deve ser um relatório (normalmente um gráfico de coluna ou uma tabela) que resume a variação de cada saída em relação à variação em cada entrada (FISH & BLODGETT, 2003; DELEN *et al.*, 2006).

Delen *et al.* (2006), Zeng e Huang (2014), Chang (2005) e Çodur e Tortum (2015) utilizaram análise de sensibilidade para interpretar os resultados dos modelos desenvolvidos. Zeng *et al.* (2016a) e Zeng *et al.* (2016b), baseando-se em Setiono e Thong (2004), propuseram um método de extração e interpretação de regras das RNA. Os autores procederam ao estabelecimento das regras e de suas condições, bem como de suas consequências. A inconveniência é que, em geral, são geradas muitas regras e estas são complexas, o que torna a interpretação dificultada.

Embora não tenha sido empregado nos artigos analisados, outro método de avaliação da importância dos parâmetros de entrada no resultado das RNA é o proposto por Howes e Crook (1999). Os autores propuseram o cálculo de índices para analisar a importância relativa das variáveis de entrada, sendo eles: influência geral (GI), influência específica (SI) e influência potencial (PI). GI é utilizado para avaliar a influência geral dos parâmetros de entrada, SI para a influência específica de parâmetros de entrada individuais nos resultados das RNA em questão, e PI para a influência potencial de cada parâmetro de entrada na resposta da rede.

Mais recentemente, Humphrey *et al.* (2017) e Beck (2018) propuseram e disponibilizaram em código aberto, funções capazes de gerar diagrama de interpretação de redes neurais, fatores de importância de variáveis explicativas e análise de sensibilidade das variáveis-resposta às mudanças nas variáveis de entrada. Humphrey *et al.* (2017) também recomendaram métodos para avaliar a validade replicativa e validade estrutural de modelos preditivos, especialmente mediante análise de resíduos. Tais avanços buscam minimizar (ou superar) limitações das RNA, possibilitando que seja tirado maior proveito desta técnica.

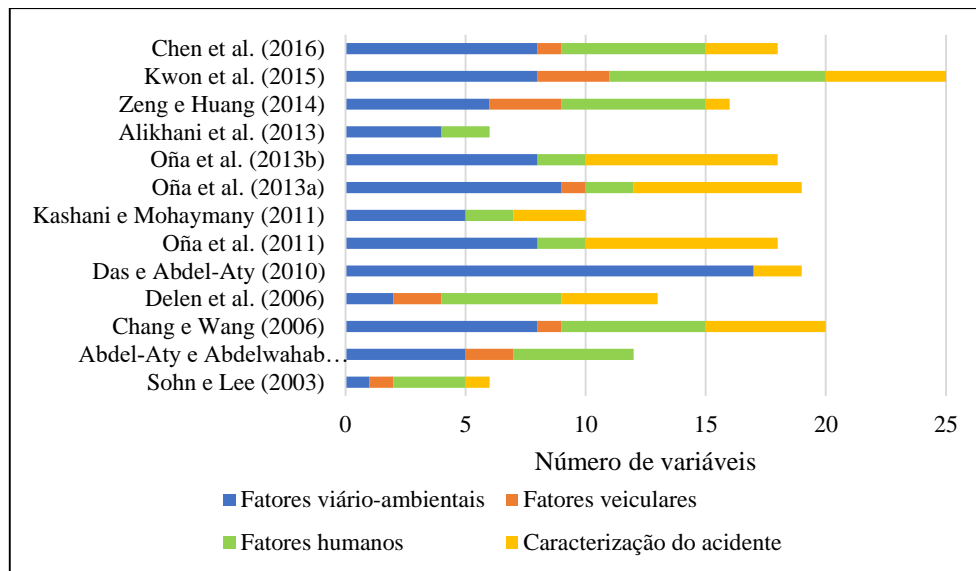
## **2.4. VARIÁVEIS EXPLICATIVAS**

Uma importante etapa no processo de modelagem é a escolha das variáveis explicativas, a qual é dependente do propósito da modelagem. A inclusão de uma variável supõe que esta esteja associada, de forma significativa, à variável dependente de interesse. Logo, a seleção dos preditores depende do julgamento e conhecimento acerca dos dados, experiência no processo de modelagem e disponibilidade de dados (HAUER, 2015).

Conforme Madalozo (2003), as variáveis do traçado em planta, em perfil ou da seção transversal de uma rodovia podem estar associadas ao número de acidentes ocorridos. Abdel-Aty e Radwan (2000), Carson e Mannering (2001) e Pérez (2002) reiteram a afirmação, chamando especial atenção para os diferentes níveis de risco em trechos retos e curvos; apontam ainda a curvatura horizontal como variável geométrica mais significativa. Cardoso (1998) e Nogueira (1995) também apontam o controle de acesso à rodovia e uso do solo como fatores contribuintes para os acidentes.


Assim, é fundamental conhecer as variáveis utilizadas por outros pesquisadores em processos de modelagem similares aos desenvolvidos no presente trabalho. Na avaliação dos modelos, as variáveis foram agrupadas em quatro classes: fatores humanos, fatores viário-ambientais, fatores veiculares e caracterização do acidente. A Figura 2.4 traz as variáveis utilizadas em cada estudo de modelagem de classificação de acidentes por severidade. Pelo disposto na figura, é possível observar que todos os estudos incorporaram fatores viário-ambientais na modelagem, mesmo que somente um, como ocorre no trabalho de Sohn e Lee (2003). Além deste modelo, apenas Delen *et al.* (2006) e Kwon *et al.* (2015) não tiveram como maior proporção de variáveis, aquelas relacionadas à via e condições ambientais. Em contraposição, os fatores veiculares

foram os de menor utilização, inexistindo nos modelos de Das e Abdel-Aty (2010), Oña *et al.* (2011), Kashani e Mohaymany (2011), Oña *et al.* (2013b) e Alikhani *et al.* (2013) e tendo participação pouco expressiva nos demais modelos. Já os fatores humanos e os fatores de caracterização do acidente tiveram uso em praticamente todos os modelos.



**Figura 2.4-** Grupos de variáveis utilizadas na modelagem de acidentes por severidade

A Figura 2.5 traz as variáveis empregadas para cada modelo de frequência de acidentes. Nota-se a hegemonia dos fatores viário-ambientais em todos os modelos, a maioria deles apenas com esse grupo de variáveis. Todos os trabalhos valeram-se destes fatores para o desenvolvimento dos modelos.



**Figura 2.5-** Grupos de variáveis utilizadas na modelagem de frequência de acidentes

Nos modelos de frequência de acidentes, os dados são agrupados por segmentos da rodovia, razão pela qual não configuram como dados individuais de acidentes (e suas respectivas características). Tal fato justifica a inexpressividade dos fatores veiculares, fatores humanos e caracterização do acidente neste tipo de modelagem. Devido à necessidade de agregação dos dados, como destacado por Kockelman e Kweon (2002), as características individuais dos acidentes, usuários e veículos são de difícil incorporação nos atributos dos segmentos e, na maioria das vezes, não faz sentido ou tem significância no modelo.

Os modelos de frequência e severidade de acidentes disponíveis na literatura (DAS & ABDEL-ATY, 2011; ZENG *et al.*, 2016b), também utilizaram da segmentação das rodovias analisadas, e assim, suas variáveis foram basicamente, relacionadas aos fatores viário-ambientais. Na Tabela 2.3 estão apresentadas as principais variáveis explicativas empregadas para cada tipo de modelo.

Além de conhecer as variáveis explanatórias empregadas em estudos anteriores, saber quais foram identificadas como mais importantes no modelo, pode auxiliar na escolha das variáveis para modelagem em novos estudos. Na Tabela 2.4 estão apresentadas as variáveis mais fortemente relacionadas à severidade ou frequência de acidentes nos trabalhos revisados.

**Tabela 2.3 - Principais variáveis explicativas utilizadas nos modelos**

	<b>Viário-ambientais</b>	<b>Humanos</b>	<b>Veiculares</b>	<b>Caracterização do acidente</b>
<b>Modelos de severidade</b>	Condições atmosféricas; Iluminação; Trecho da via; Tipo de acostamento	Sexo; Idade; Uso do cinto de segurança	Tipo de veículo; Idade do veículo	Tipo de acidente; Horário; Dia da semana
<b>Modelos de frequência</b>	Volume de tráfego; Extensão do segmento; Alinhamento horizontal; Largura do acostamento; Trecho da via	Sexo		Ano; Estação do ano; Veículos envolvidos no acidente
<b>Modelos de frequência e severidade</b>	Volume de tráfego; Largura do acostamento; Limite de velocidade; Largura da via; Condição do pavimento			Horário; Dia da semana

Dentre os modelos de classificação de severidade dos acidentes, as variáveis tidas como mais importantes e que são possíveis de compor a abordagem deste trabalho (segmentos da rodovia) são: velocidade máxima regulamentada, volume de tráfego, uso do solo, divisão de pista, superfície do pavimento, sinalização horizontal, largura da via e número de faixas. Além disso, nota-se que o volume de tráfego, extensão do segmento, alinhamento horizontal e velocidade



máxima regulamentada são os fatores mais importantes entre os modelos que lidam com a previsão de frequência de acidentes por segmento.

**Tabela 2.4 - Principais fatores contribuintes para severidade ou ocorrência de acidentes**

<b>Referência</b>	<b>Principais fatores contribuintes</b>
<i>Modelos de previsão de acidentes por severidade</i>	
<b>Abdel-Aty e Abdelwahab (2004)</b>	Sexo do condutor; Velocidade máxima regulamentada; Uso do cinto de segurança; Tipo de veículo; Ponto de impacto; Uso do solo
<b>Delen et al. (2006)</b>	Uso do cinto de segurança; Tombamento; Sexo do condutor; Idade do condutor; Uso de álcool ou drogas; Tipo de veículo
<b>Chang e Wang (2006)</b>	Tipo de colisão; Circunstâncias contribuintes; Ação do veículo/condutor
<b>Das e Abdel-Aty (2010)</b>	Presença de estacionamento; Velocidade máxima regulamentada; Porcentagem de veículos pesados; Barreira central; Volume de tráfego
<b>Oña et al. (2011)</b>	Tipo de acidente; Idade do condutor; Iluminação; Número de lesões
<b>Kashani e Mohaymany (2011)</b>	Uso do cinto de segurança; Causa do acidente; Superfície do pavimento; Condições atmosféricas
<b>Oña et al. (2013a)</b>	Iluminação; Tipo de acidente; Sexo do condutor; Condições atmosféricas; Causa do acidente; Horário do acidente
<b>Oña et al. (2013b)</b>	Número de veículos envolvidos; Número de lesões; Condições atmosféricas; Sinalização horizontal; Largura da via
<b>Zeng e Huang (2014)</b>	Sexo do condutor; Idade do condutor; Dispositivos de segurança (ex.: cinto de segurança); Idade do veículo; Porcentagem de veículos pesados; Ponto de impacto
<b>Kwon et al. (2015)</b>	Tipo de colisão; Categoria de infração; Movimento precedente à colisão; Tipo de rodovia
<b>Chen et al. (2016)</b>	Uso do cinto de segurança; Superfície do pavimento; Condições atmosféricas; Dano máximo ao veículo; Uso de álcool ou drogas; Idade do condutor; Número de faixas; Características demográficas do condutor
<i>Modelos de previsão de frequência de acidentes</i>	
<b>Chang (2005)</b>	Segmento em área militar; Existência de interseção; Porcentagem de veículos pesados; Número de faixas; Volume de tráfego
<b>Chang e Chen (2005)</b>	Volume de tráfego; Precipitação; Porcentagem de veículos pesados; Curvatura horizontal
<b>Xie et al. (2007)</b>	Extensão do segmento; Volume de tráfego; Largura de faixa
<b>Li et al. (2008)</b>	Volume de tráfego; Largura do acostamento
<b>Çodur e Tortum (2015)</b>	Grau de curvatura vertical; Volume de tráfego; Grau de curvatura horizontal; Extensão do segmento
<b>Zeng et al. (2016a)</b>	Volume de tráfego; Velocidade máxima regulamentada; Precipitação anual; Extensão do segmento; Barreira central; Ponto de ônibus
<i>Modelos de previsão de severidade e frequência de acidentes</i>	
<b>Das e Abdel-Aty (2011)</b>	Volume de tráfego; Velocidade máxima regulamentada; Largura da via; Resistência à derrapagem
<b>Zeng et al. (2016b)</b>	Volume de tráfego; Extensão do segmento; Velocidade máxima regulamentada; Ponto de ônibus; Precipitação anual

Essas constatações acerca das variáveis utilizadas nos modelos revisados são úteis tanto para auxiliar na escolha das variáveis independentes do modelo a ser desenvolvido, como na discussão e confrontamento dos resultados obtidos.

## 2.5. SEGMENTAÇÃO DA RODOVIA

A previsão de frequência de acidentes em trechos de rodovia é significativamente influenciada pela estratégia de segmentação adotada, especialmente pela extensão do segmento. Tanto segmentos muito extensos como muito curtos são inadequados. Por um lado, segmento muito longo implica na perda de informações detalhadas e, noutra mão, segmento muito curto possui mais variações e conseqüente introdução de incerteza nos modelos (COOK *et al.*, 2011; LU *et al.*, 2013; GREEN *et al.*, 2017). Valores mínimos e máximos de extensão de segmento não são óbvios nem consensuais, dado que o processo de segmentação é, na maioria dos casos, condicionado pelos atributos escolhidos e pelo foco da análise de segurança (CAFISO *et al.*, 2008; BORSOS *et al.*, 2014). Além disso, Green e Agent (2011) e Qin e Wellner (2012) destacam a influência da precisão da localização dos acidentes na escolha do tamanho do segmento.

Dentre as diversas abordagens existentes para o propósito de segmentação, destacam-se: divisão em segmentos homogêneos e divisão em segmentos de extensão fixa. Cada uma apresenta vantagens e limitações. Na primeira abordagem, o resultado é um conjunto de elementos viários individuais contíguos de comprimento variável, apresentando homogeneidade em algumas características, tais como: geometria, volume de tráfego e controle de tráfego (CASTELLÓ, 2017). O Manual de Segurança Viária americano (*Highway Safety Manual*, HSM) traz critérios para avaliação da homogeneidade e divisão de segmentos. Nas rodovias de pista dupla baseia-se, essencialmente, nos atributos: volume de tráfego, tipo de divisão de pista, inclinação de talude lateral, tipo de acostamento, largura de acostamento, largura de faixa de rolamento, presença de iluminação e presença de controle eletrônico de velocidade (AASHTO, 2010).

Quanto mais variáveis são utilizadas para avaliar a homogeneidade, menores são os segmentos homogêneos resultantes (RESENDE & BENEKOHAL, 1997). E, segmentos menores tipicamente reduzem a robustez estatísticas dos MPA. Além disso, um número maior de segmentos, devido a característica de aleatoriedade dos acidentes, resultará em mais segmentos com zero acidentes (SOULEYRETTE *et al.*, 2007).

De outro lado, no caso de segmentos com extensão fixa, o desafio é estabelecer a extensão ótima do segmento. Resende e Benekohal (1997) foram um dos primeiros a investigar a

influência da extensão do segmento na previsão de taxas de acidentes em trechos rodoviários, tendo utilizados valores entre 0,1 milha e 1 milha (0,161 km e 1,61 km) com incrementos sucessivos de 0,1 milha. Cenek *et al.* (1997) utilizaram segmentos de extensão fixa de 200 m, Zhang e Ivan (2005) dividiram a rodovia em segmentos de 1 km e Costa (2013) utilizou segmentos de 200 m e 400 m. Quanto aos trabalhos sistematizados na RSL, Chang e Chen (2005) utilizaram segmentos de 1 km e Das e Abdel-Aty (2011) utilizou 805 m.

Diante da variedade de conceitos e métodos para o propósito da segmentação sem, entretanto, existir preferência entre eles, diferentes investigadores têm dispendido esforços na busca da segmentação ideal. Cafiso *et al.* (2018) é um exemplo recente disso. Os autores avaliaram a influência de quatro diferentes tipos de segmentação em modelos de previsão de acidentes baseados no volume de tráfego e características geométricas. As abordagens adotadas foram: (i) segmentos homogêneos, conforme HSM; (ii) segmentos compostos por 2 curvas e 2 tangentes sucessivas; (iii) segmentos com extensão fixa de 650 m; (iv) segmentos homogêneos onde todas as variáveis são constantes.

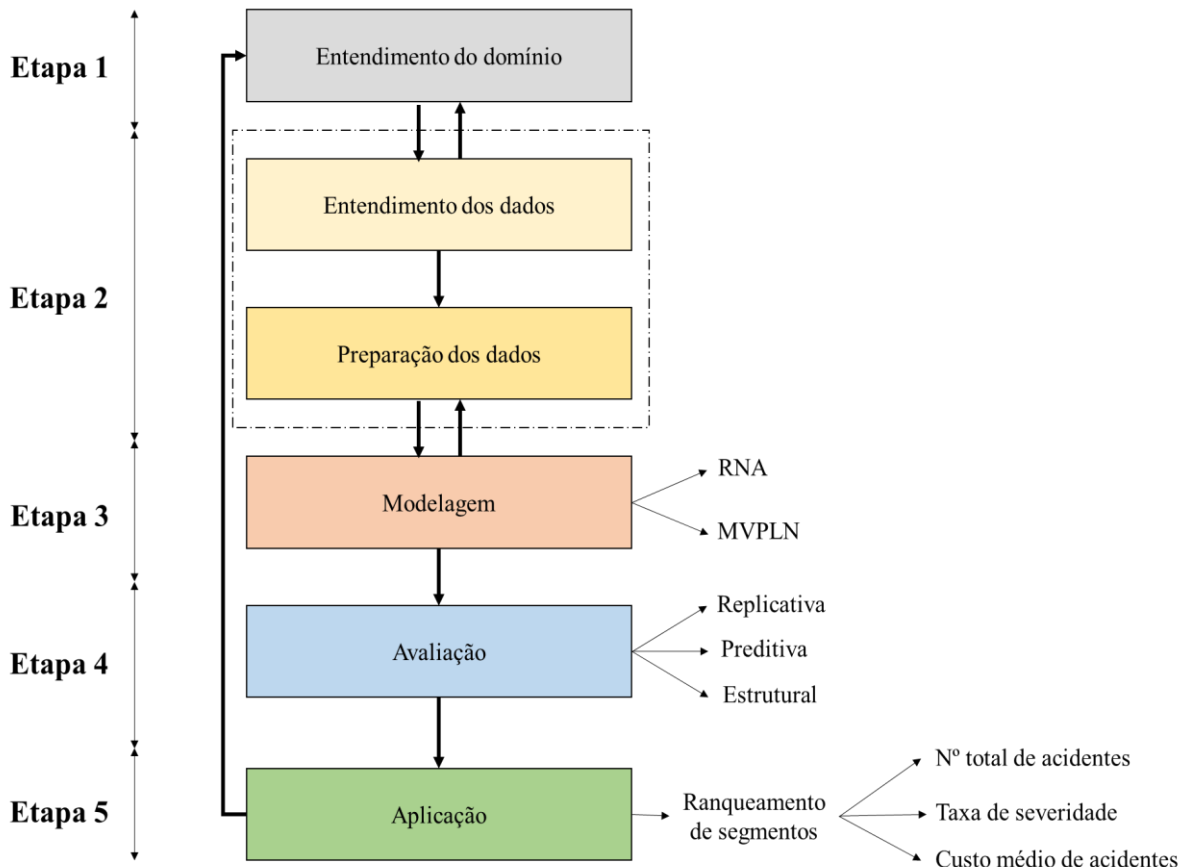
As diferentes abordagens foram comparadas com base na adequação do modelo, usando análise dos resíduos acumulados (*CURE Plot*) e critério de quasiverossimilhança sob o modelo de independência *Quasi-likelihood under the Independence Model Criterion* (QIC). Os resultados obtidos indicaram que as abordagens ii (2 curvas e 2 tangentes) e iii (segmento de extensão fixa) apresentaram os melhores resultados, ao passo que as abordagens de segmentação homogênea, especialmente a iv, conduziram aos piores resultados. A segmentação homogênea resultou em muitos segmentos curtos, com localização imprecisa dos acidentes e grande número de segmentos caracterizados com zero acidentes, dificultando a inferência estatística. Os autores destacaram o potencial uso dos segmentos de extensão fixa, considerando os resultados promissores e, por esse tipo de abordagem ser mais flexível em aplicações práticas. O comprimento do segmento pode, portanto, ser determinado pela disponibilidade e qualidade de dados, além de outros fatores que possam otimizar os MPA.

Também recentemente, Green (2018) abordou a relação entre o comprimento do segmento e os atributos da rodovia e, sua influência na eficácia dos modelos de previsão. Para tanto o autor utilizou 16 diferentes segmentações da rodovia de pista dupla, variando entre 0,1 (161 m) milha e 5 milhas (8,047 km). Concluiu-se que, para os dados analisados, a extensão ideal era de 2 milhas (3,2 km).

Posto isto, embora seja um tópico ainda em exploração, deve-se considerar os resultados promissores do uso de segmentos de extensão fixa (CAFISO *et al.*, 2018), a disponibilidade e tipos de dados (reforçado por KOOREY, 2009), a precisão dos dados coletados - acidentes, operação e geometria - (OGLE *et al.*, 2011; QIN & WELLNER, 2012) e dependência da adequação da modelagem às características dos dados, a segmentação da rodovia em trechos de extensão fixa tem sido encarada como uma das melhores estratégias, que pelos motivos supracitados, foi utilizada neste trabalho.

### 3. MÉTODO

Neste capítulo são apresentadas as abordagens, etapas e procedimentos metodológicos empregados para o alcance dos objetivos da tese. Baseado no proposto por Chapman *et al.* (2000), na Figura 3.1 está apresentada a sequência de etapas desenvolvidas.



**Figura 3.1 - Método adotado na pesquisa**

#### 3.1.ETAPA 1 - ENTENDIMENTO DO DOMÍNIO

Trata-se da fase inicial do processo e é focada no entendimento dos objetivos e requisitos da pesquisa, do ponto de vista do domínio (contexto do estudo). Consistiu, portanto, da compreensão do cenário e do problema de pesquisa. Tais aspectos foram abordados nos Capítulos 1 e 2. Ainda assim, foi necessário tratar especificamente da área de estudo.

- **Definição da área de estudo**

Com vistas ao atendimento do propósito do trabalho, foi necessário delimitar a área de estudo para o desenvolvimento dos modelos de previsão de acidentes. Inicialmente observou-se o atendimento ao foco do estudo: rodovias de pista dupla. Posteriormente, foram consideradas as características técnicas e operacionais dos trechos rodoviários, bem como a disponibilidade de dados. Mediante essa análise, foi possível definir a área de estudo mais compatível para a pesquisa.

### **3.2. ETAPA 2 - ENTENDIMENTO E PREPARAÇÃO DOS DADOS**

Esta etapa destinou-se a identificar as fontes de dados e os processos de coleta associados, os formatos em que os dados estão disponíveis e a exploração inicial destes. Em seguida, a partir dos dados brutos, foram extraídas informações para caracterização das variáveis explicativas e constituição das bases de dados que foram utilizadas para o desenvolvimento dos MPA.

- **Dados de acidentes**

Um passo inicial no processo de modelagem da segurança viária foi a identificação das fontes de dados de acidentes, bem como a disponibilidade e qualidade desses registros. Assim, foi possível definir a melhor estratégia para coleta, consolidação e utilização dos dados relativos ao trecho rodoviário selecionado. Ademais, foi realizada a exploração inicial dos dados, de forma a verificar inconsistências, padrões ou informações úteis para a modelagem.

- **Dados para modelagem**

Além do entendimento dos dados de acidentes, foi realizada a identificação dos dados de geometria, pavimento e operação rodoviária disponíveis e que tinham potencial aplicação na modelagem. Tal análise permitiu identificar os tipos de dados, formato de arquivos, fontes de dados e limitações de sua utilização.

- **Segmentação da rodovia**

Anterior à caracterização das variáveis, foi necessário definir a estratégia de segmentação da rodovia. Como já discutido no capítulo anterior, dadas as indicações de maior adequabilidade e oportunidade de avanços quanto à identificação da extensão “ideal” de segmentos, fez-se a opção por segmentos de extensão fixa.

Devido às diferenças nas características geométricas e operacionais, assim como feito por Chang e Chen (2005), as Pistas Norte (PN) e Sul (PS) da rodovia tiveram que ser consideradas separadamente.

Similar ao que foi desenvolvido por Green (2018), no entanto, valendo-se de mais variáveis explanatórias e emprego de técnicas de AM, a rodovia foi dividida em segmentos de 500 m, com sucessivos incrementos de 500 m até 5 km (resultando em 10 segmentações), o que permitiu avaliar a influência da extensão dos segmentos no ajuste dos modelos.

O procedimento de divisão e caracterização dos segmentos consistiu, basicamente, das seguintes etapas:

- 1 – Obtenção do traçado georreferenciado da rodovia, a partir do uso de imagens de satélite (*Google Earth* e *OpenStreetMap*), com recurso ao *software* SpatialManager™;
- 2 – Exportação do traçado da rodovia para plataforma de desenho assistido por computador (AutoCAD®);
- 3 – Verificação das coordenadas geográficas fornecidas no Relatório de Monitoração no traçado georreferenciado e realização de ajustes;
- 4 – Localização dos acidentes de trânsito ao longo das pistas da rodovia;
- 5 – Identificação de pontos de interesse para caracterização das variáveis explicativas, tais como: entradas e saídas da via, pontos de mudança de tipo de divisão da via, pontos de mudança de largura de acostamento e canteiro central, locais de controladores de velocidade e iluminação;
- 6 – Divisão dos eixos da rodovia, segundo cada pista, em segmentos de 500 m; 1 km; 1,5 km; 2 km; 2,5 km; 3 km; 3,5 km; 4 km; 4,5 km; 5 km; e
- 7 – Caracterização dos segmentos segundo os atributos constantes em cada um deles.

- **Variáveis explicativas**

A revisão de trabalhos de modelos de previsão de acidentes, entendimento do fenômeno, exploração dos dados disponíveis e propósito da pesquisa nortearam a definição das variáveis explicativas. Estas se enquadraram em três grupos: características geométricas, características operacionais e características do pavimento.

- **Construção das bases de dados**

Após caracterização dos segmentos, segundo diferentes extensões, para cada pista e nos dois períodos de tempo analisados, foram construídas as bases de dados. O detalhamento das etapas descritas nos itens 3.1 e 3.2 está apresentado no Capítulo 4.

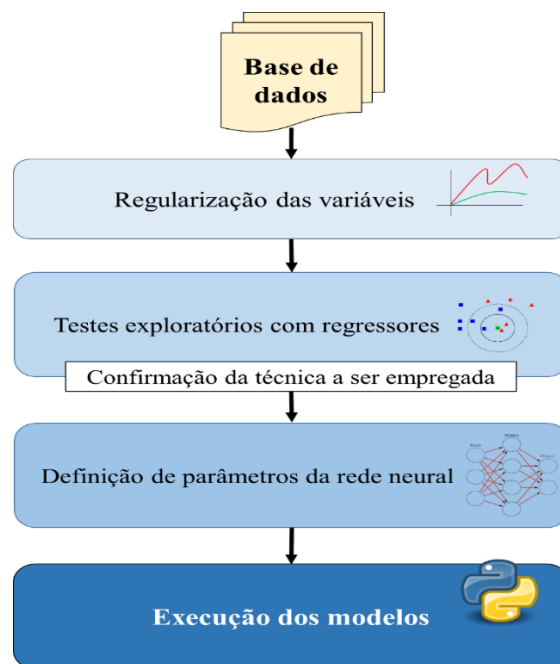
### 3.3. ETAPA 3 - MODELAGEM

Após a preparação dos dados, deu-se início ao ajuste dos modelos de previsão de acidentes. O foco do estudo foi o emprego de técnicas de Aprendizado de Máquina (AM), tendo sido conduzida uma análise exploratória das principais técnicas aplicáveis e, mediante análise de resultados e constatações advindas da revisão de literatura, decisão pela técnica empregada.

Mesmo não constituindo o objetivo principal da pesquisa, para fins de comparação e fortalecimento de discussões, também foram desenvolvidos modelos de previsão de acidente por meio do emprego de modelos multivariados Poisson lognormal (MVPLN). Os procedimentos detalhados do processo de modelagem estão apresentados no Capítulo 5.

#### 3.3.1. Aprendizado de máquina

Na Figura 3.2 está apresentado o esquema geral dos procedimentos realizados para fins da modelagem com uso de técnica de Aprendizado de Máquina.



**Figura 3. 2-** Etapas da modelagem com técnica de aprendizado de máquina



- **Estágio 1** – o passo inicial da modelagem foi definir o procedimento de regularização dos dados, transformando todas as variáveis para a mesma ordem de grandeza. Foram testados quatro tipos de regularização: padronização, padronização e transformação logarítmica do volume de tráfego, normalização, e normalização e transformação logarítmica do volume de tráfego.

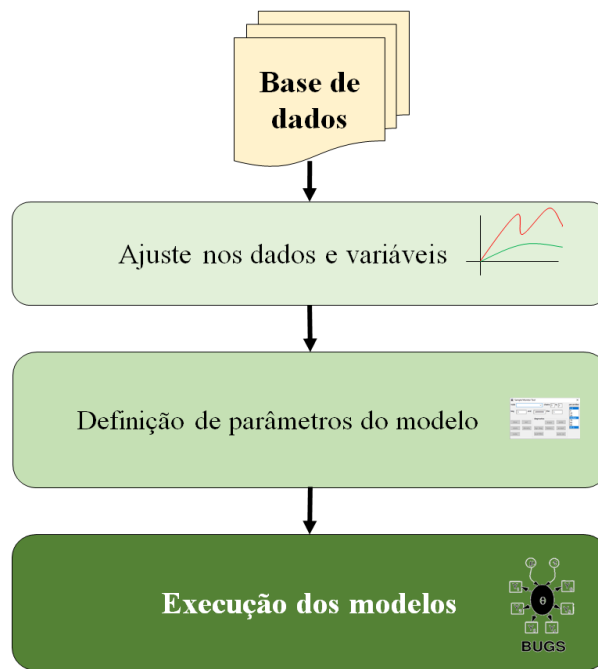
- **Estágio 2** – embora se tenha constatado maior aderência das RNA ao propósito da pesquisa, explorou-se inicialmente, para fins confirmatórios, outras técnicas de regressão, a saber: *Random Forest* e *kNN*. Os resultados advindos do emprego de RNA, *kNN* e *Random Forest* foram comparados em termos de Erro Relativo (ER), o que, juntamente com os achados da revisão sistemática, confirmaram maior adequação das redes neurais ao tipo de modelagem.

- **Estágio 3** – confirmado o emprego de redes neurais, os parâmetros foram definidos pautando-se nas recomendações da literatura e experimentações dos dados. Foi utilizada uma rede neural do tipo *multilayer perceptron* (MLP), contendo de 1 a 10 camadas ocultas com 25 neurônios cada, a depender da extensão do segmento. O processo de treinamento deu-se mediante uso do algoritmo *backpropagation* associado ao otimizador *Adam* (*Adaptive moment estimation*), com função de ativação ReLU (função retificadora linear) e taxa de aprendizado. Como estratégia de convergência e minimização de *overfitting* foram empregados o *early stopping* e *transfer learning*.

- **Estágio 4** – Para cada um dos 40 modelos, empregou-se o procedimento *repeated holdout* (RHO) aos respectivos conjuntos de dados, de forma que houve o particionamento aleatório de cada conjunto de dados em dois subconjuntos: 80% (treinamento) e 20% (teste), com 30 repetições executadas. Os modelos foram desenvolvidos com recurso ao *Scikit learn* (PEDREGOSA *et al.*, 2011), biblioteca de aprendizado de máquina de uso geral escrita em *Python*.

### 3.3.2. Modelo multivariado Poisson lognormal (MVPLN)

Em relação a modelagem estatística com recurso ao MVPLN, são apresentadas na Figura 3.3 as etapas gerais executadas.



**Figura 3.3** - Etapas da modelagem com técnica de aprendizado de máquina

- **Estágio 1** – inicialmente, foi necessário ajustar os dados e variáveis da base de dados já construída, de forma a atender às especificidades da sintaxe do *software* utilizado para proceder à modelagem com MVPLN. Também foi testada a transformação de escala de algumas variáveis para melhorar o ajuste dos modelos.

- **Estágio 2** – parâmetros como tipo de distribuição *a priori*, precisão e matriz de variância-covariância foram definidos. Também foi estabelecido o critério de convergência e finalização da execução.

- **Estágio 3** – os modelos foram executados mediante simulação de Monte Carlo via cadeias de Markov (MCMC) com o uso da plataforma OpenBUGS versão 3.2.3.

### 3.4. ETAPA 4 – AVALIAÇÃO

A avaliação – podendo ser entendida como validação – é uma importante etapa no desenvolvimento de modelos, tendo por objetivo verificar se um modelo é apropriado e útil para a finalidade a que se destina, aumentando assim a confiança quanto aos resultados obtidos (POWER, 1993; OH *et al.*, 2003; BIONDI *et al.*, 2012).

Considerando a necessidade de executar um protocolo consistente de validação, conforme proposto por Humphrey *et al.* (2017), esse processo foi conduzido em três vertentes: i) validade replicativa; ii) validade preditiva; e, iii) validade estrutural. A seguir estão apresentadas as ações conduzidas para fins de validação, enquanto que o detalhamento dos métodos empregados consta no Capítulo 5 e os respectivos resultados no Capítulo 6.

- **Fase 1: Validação replicativa** – fase destinada a verificar se o modelo capturou adequadamente o relacionamento subjacente nos dados utilizados para calibração do modelo (treinamento). Os procedimentos descritos a seguir foram executados tanto para os modelos de RNA quanto para os modelos MVPLN.

- **Passo 1** – cálculo de medidas de desempenho (métricas de erro e  $R^2$ );
- **Passo 2** – construção de gráficos dos resultados de previsão e resíduos;
- **Passo 3** – comparação entre as medidas de desempenho como passo inicial da seleção dos melhores modelos;
- **Passo 4** – análise dos gráficos de resultados para verificação de validade replicativa dos modelos; e
- **Passo 5** – análise conjunta dos resultados para seleção do melhor modelo para cada pista e período, apontando 4 modelos (PN\_2011\_2014, PN\_2015\_2018, PS\_2011\_2014 e PS\_2015\_2018).

- **Fase 2: Validação preditiva** – fase em que é verificado se o modelo pode generalizar além do intervalo de dados fornecido no treinamento, ou seja, sobre um conjunto de dados independente. Esta fase foi executada apenas para os modelos de RNA, dadas as limitações dos modelos MVPLN esclarecidas no Capítulo 5.

- **Passo 1** – cálculo de medidas de desempenho (métricas de erro e  $R^2$ );
- **Passo 2** – construção de gráficos dos resultados de previsão e resíduos;
- **Passo 3** – comparação entre as medidas de desempenho auferidas no conjunto de treinamento e no conjunto de teste; e
- **Passo 4** – análise dos gráficos de resultados para verificação de validade preditiva dos 4 modelos selecionados.

- **Fase 3: Validação estrutural** – etapa conduzida para averiguar a plausibilidade do comportamento do modelo quando comparado ao conhecimento *a priori* do sistema modelado. Para a abordagem com RNA, essa etapa é conduzida por meio emprego de métodos de análise de sensibilidade, ao passo que, para MVPLN essa verificação é realizada a partir dos próprios coeficientes estimados do modelo.

Os passos executados para os modelos de RNA foram:

- **Passo 1** – aplicação do método de Sobol’;
- **Passo 2** – aplicação do método de Morris;
- **Passo 3** – aplicação do método de perfil de sensibilidade;
- **Passo 4** – cálculo dos fatores de importância das variáveis; e
- **Passo 5** – análise dos resultados e discussão sobre a interpretabilidade dos modelos selecionados.

Os procedimentos realizados para os modelos MVPLN foram:

- **Passo 1** – verificação da significância das variáveis;
- **Passo 2** – inferências a partir dos valores de elasticidade das variáveis significativas para os modelos selecionados;
- **Passo 3** – aplicação do método *backward* de seleção de variáveis para cada modelo; e
- **Passo 4** – análise dos resultados dos modelos com variáveis priorizadas.

### 3.5. ETAPA 5 – APLICAÇÃO

A etapa final do método da pesquisa é a aplicação dos resultados da modelagem, a fim de verificar sua empregabilidade para ranqueamento e identificação de segmentos críticos da rodovia. Para tanto, foram adotados os seguintes critérios de ranqueamento:

- **Número total de acidentes** – o número total de acidentes foi obtido pela soma dos valores de *NASV*, *NACV* e *NACM* de cada segmento;

- **Taxa de severidade dos acidentes** – obtida pela relação entre a Unidade Padrão de Severidade (UPS) e fatores de exposição (volume de tráfego, extensão do segmento e tempo de análise); e
- **Custo médio dos acidentes** – tomando a estimativa do custo médio de acidentes de IPEA (2015) foi possível calcular o custo médio total dos acidentes de cada segmento.

Para cada critério foram confeccionados gráficos de dispersão (para avaliar a convergência entre os valores observados e previstos) e 3 ranqueamentos contendo os 25 segmentos mais bem classificados:

- i) O primeiro, baseado nos dados observados, servindo como referência;
- ii) O segundo, desenvolvido a partir dos valores previstos pelos modelos de RNA; e
- iii) O terceiro, baseado nas previsões do modelo MVPLN.

Em seguida, os seguintes passos foram procedidos:

- **Passo 1** – análise de concordância entre *rankings* em termos de número total de acidentes para cada um dos modelos selecionados;
- **Passo 2** – análise de concordância entre *rankings* em termos de taxa de severidade de acidentes para cada um dos modelos selecionados;
- **Passo 3** – identificação de segmentos críticos para cada modelo selecionado;
- **Passo 4** – análise de concordância entre *rankings* em termos de custo médio total de acidentes; e
- **Passo 5** – priorização dos segmentos críticos.

A descrição detalhada dos procedimentos empregados e dos resultados obtidos estão apresentados no Capítulo 7.

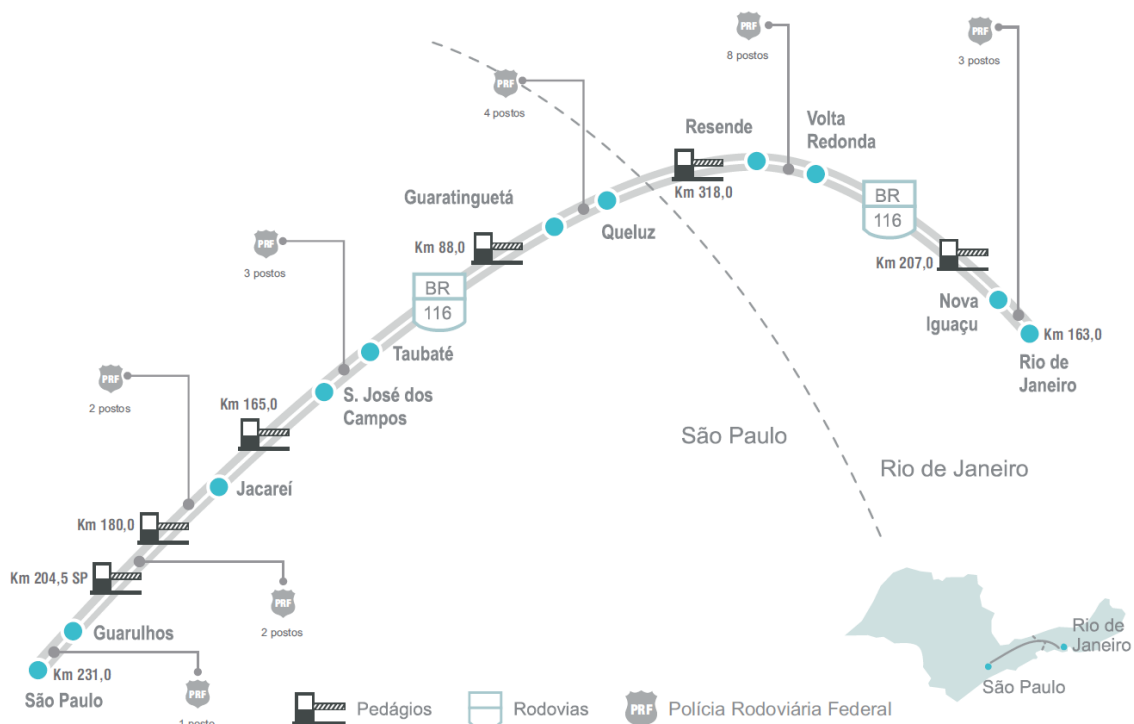
## 4. DESCRIÇÃO DA INFORMAÇÃO INTEGRADA NAS BASES DE DADOS

Neste capítulo é feita a descrição de toda a informação integrada nas bases de dados utilizadas no processo de modelagem.

### 4.1. ENTENDIMENTO DO DOMÍNIO

Alinhado ao propósito do estudo e mediante análise das rodovias com potencial para utilização e, ainda, considerando a disponibilidade e qualidade de dados, optou-se por estudar a rodovia Presidente Dutra. O trecho em questão é o da BR-116 entre km 231,6 e km 0 no estado de São Paulo (SP) e km 333,5 e km 163 no estado do Rio de Janeiro (RJ), perfazendo um total de 402,1 km. A rodovia, do ponto de vista funcional, compõe o Sistema Arterial Primário, tendo por principal finalidade proporcionar alto nível de mobilidade para grandes volumes de tráfego.

Quanto à classificação técnica, enquadra-se como uma rodovia arterial de pista dupla com separação central (canteiro ou barreira) da classe I-A, com controle parcial de acessos. Na Figura 4.1 está apresentado o mapa do trecho analisado.

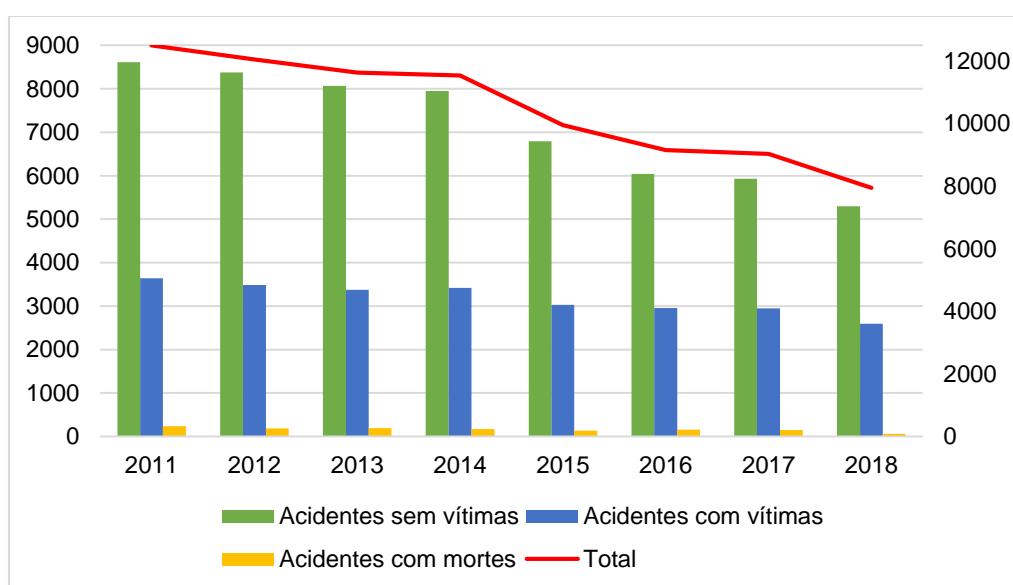


**Figura 4.1 - Mapa da concessão Nova Dutra**  
Fonte: ANTT (2014)

## 4.2. ENTENDIMENTO DOS DADOS

O registro de dados de acidentes de trânsito em rodovias federais brasileiras está sob responsabilidade da Polícia Rodoviária Federal (PRF), apoiada pelas concessionárias supervisionadas pela Agência Nacional de Transportes Terrestres (ANTT) no caso de rodovias concedidas. Diante disso, inicialmente buscou-se a unificação das duas bases de dados, verificando-se, entretanto, que a incompatibilidade entre as bases dificulta o processo, resulta em elevada redução do número de registros e gera ganho de informação com baixo potencial de emprego na modelagem. Dito isto, decidiu-se utilizar apenas a base de dados da ANTT.

Foram considerados dados de acidentes relativos aos anos de 2011, 2012, 2013, 2014, 2015, 2016, 2017 e 2018 no trecho em estudo. Na Figura 4.2 estão apresentados os números absolutos de acidentes registrados, por tipo, na série histórica considerada. O número total de acidentes no período foi de 83.784.



**Figura 4.2** - Acidentalidade no período 2011-2018 no trecho da BR-116/SP/RJ  
Fonte: ANTT (2019)

Dentre as constatações resultantes do entendimento dos dados de acidentes, a principal foi identificar a queda acentuada no número total de acidentes após o ano de 2014. Isso decorre da redução do número de acidentes sem vítima que, corroborado pela exploração dos dados, parece ser devido à implantação do sistema DAT (Declaração de Acidente de Trânsito), ativo desde julho de 2015. Trata-se de um instrumento oficial para registro, pela *internet*, de ocorrências de acidentes de trânsito em rodovias federais, em que ninguém tenha sido vitimado. Esse registro

é feito pelos próprios usuários direta ou indiretamente envolvidos, no prazo de até 180 dias da data do acidente.

Foi possível constatar também que a diferença no número de registros de acidentes, assim como o número de envolvidos, da Pista Norte (PN) e Pista Sul (PS), na série histórica considerada é pequena. Existe a predominância de acidentes envolvendo um ou dois veículos, especialmente choque em barreira no primeiro caso, e maior ocorrência de colisão traseira no segundo caso. Em se tratando dos dados para modelagem, conforme Hauer (2015), as variáveis no Modelo de Previsão de Acidente (MPA) devem ser as mesmas que os dados disponíveis para a tarefa prática, a qual o MPA se destina. Assim, como a proposta é que a modelagem auxilie os gestores na tomada de decisão para promoção da segurança viária, são utilizados os dados disponíveis nos (ou aos) órgãos de operação e/ou fiscalização rodoviária.

Nas rodovias federais, os trechos sob concessão dispõem dos melhores conjuntos de dados tanto em termos de organização quanto de quantidade de informações disponíveis. Ainda assim, a realidade é de dados dispersos em diferentes formatos e bases, falta de padronização e uniformidade nos registros, ausência de dados importantes e incompletude de informações, incompatibilidade com bases externas (PRF, DNIT e DATASUS, por exemplo). A exploração dos dados permitiu sinalizar à ANTT limitações e fragilidades detectadas, de forma a contribuir para a criação de um sistema unificado de dados de operação rodoviária multipropósito.

Na Tabela 4.1 está apresentado o resumo dos formatos e categorias dos dados potenciais para uso. O documento principal é o Relatório Técnico-Operacional Físico-Financeiro (RETOFF), relatório mensal em que estão contidas informações operacionais, de fiscalização e financeiras. Adicionalmente foram disponibilizados os relatórios anuais de Monitoração, Nível de Serviço e Interrupção. No entanto, estes não dispõem de dados em toda a série histórica ou em todo o trecho da rodovia, sendo utilizados complementarmente ao RETOFF. Por fim, atendendo a pedido, a ANTT disponibilizou tabelas contendo algumas informações do traçado da rodovia, nomeadamente raio de curva horizontal.

O SIOR (Sistema Integrado de Operações Rodoviárias) do DNIT também foi utilizado para confirmação de algumas informações e obtenção de outras, especialmente quanto ao uso do solo. Além disso, a manipulação de imagens de satélite (e *softwares* associados) foi essencial para verificar e enriquecer os dados obtidos.



**Tabela 4.1 - Identificação, categorização e seleção de dados**

<b>Documento</b>	<b>Formato</b>	<b>Categoria de dados</b>	<b>Sub-categoria</b>	<b>Limitações</b>	
<b>Relatório Técnico-Operacional Físico-Financeiro (RETOFF)</b>	Tabela editável (.xls)	Operação	Volume de tráfego	Volume classificado apenas nas Praças de Pedágio	
			Velocidade média e velocidade máxima regulamentada	Velocidade média disponível apenas em alguns pontos Falta de detalhamento de mudança de velocidade máxima regulamentada	
			Demonstrativo de acidentes	Localização dos acidentes por marco quilométrico Indiferenciação de pista expressa e marginal	
			Iluminação e neblina	Neblina sofre o efeito da sazonalidade	
			Capacidade de tráfego	Necessidade de interpolação dos dados em alguns trechos	
			Passarelas	Extração de informações via diagrama esquemático	
			Condições do pavimento	Indisponibilidade de dados em toda série histórica para alguns indicadores	
			Fiscalização	Pesagem	Diversas paralisações das balanças
				Controladores eletrônicos de velocidade	Dados faltantes de veículos infratores
				Câmeras e Painéis	Indiferenciação de pista expressa e marginal
<b>Relatório de Monitoração</b>	Texto não editável (.pdf)	Sinalização	Retrorreflectância da sinalização horizontal	Avaliação de amostras de trechos da rodovia Necessidade de reestruturação dos dados em formato editável	
			Retrorreflectância da sinalização vertical	Indisponibilidade de dados em toda série histórica Indisponibilidade de dados em todos os trechos	
<b>Relatório de Nível de Serviço</b>	Texto não editável (.pdf)	Capacidade e Nível de Serviço	Capacidade e Nível de Serviço	Necessidade de reestruturação dos dados em formato editável Indisponibilidade de dados em toda série histórica	
<b>Relatório de Interrupção</b>	Tabela editável (.xls)	Interrupções da operação	Interrupções da operação	Indisponibilidade de dados em toda série histórica	
<b>Traçado da rodovia</b>	Tabela editável (.xls)	Geometria	Alinhamento vertical	Disponibilidade de apenas algumas características	
			Alinhamento horizontal	Disponibilidade de apenas algumas características	

### 4.3. PREPARAÇÃO DOS DADOS

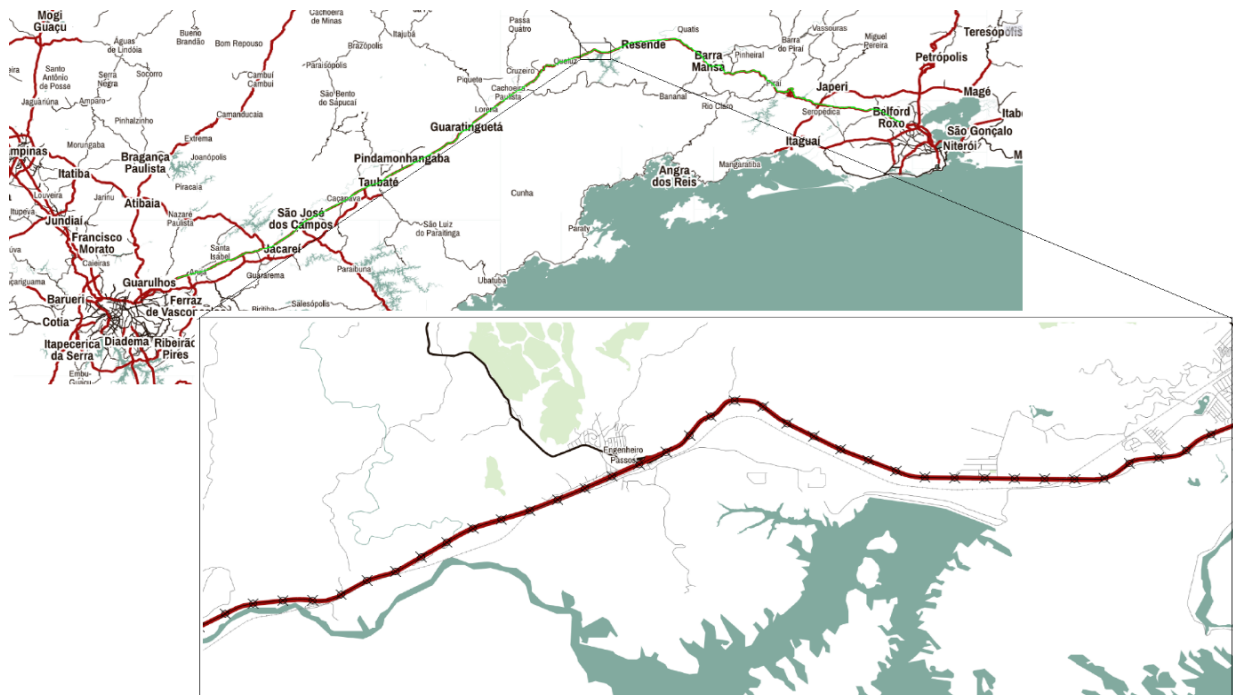
Após exploração inicial dos dados, foram definidas as variáveis a serem utilizadas na modelagem e consequente preparação dos dados a fim de obtê-las. Esta etapa teve como resultado a construção das bases de dados utilizadas no desenvolvimento dos modelos.

Em termos de segmentação, após exclusão dos trechos com existência de pista marginal, resultou a configuração apresentada na Tabela 4.2.

**Tabela 4.2 - Descrição das concessões administradas pela ANTT**

Pista	Trecho em São Paulo	Trecho no Rio de Janeiro	Extensão total
<u>Norte</u>	km 210 a km 0 (210 km)	km 333,5 a km 171 (162,5 km)	372,5 km
<u>Sul</u>	km 0 a km 210 (210 km)	km 169 a km 333,5 (164,5 km)	374,5 km

Procedeu-se à segmentação da rodovia em 500 m; 1 km; 1,5 km; 2 km; 2,5 km; 3 km; 3,5 km; 4 km; 4,5 km e 5 km. Na imagem de fundo da Figura 4.3 está assinalado, em cor verde, o eixo da rodovia. Em primeiro plano, uma imagem ampliada permite visualizar a divisão entre segmentos de 500 m.



**Figura 4.3 - Eixo da rodovia e detalhes da segmentação**

### **4.3.1. Variáveis Explicativas**

Os principais fatores identificados nos trabalhos sistematizados na RSL contribuíram para a definição das variáveis explicativas a serem utilizadas no processo de modelagem. As características individuais (usuários, veículos e condições climáticas), como já discutido, não serão utilizadas como variáveis, dado o uso de segmentos na modelagem. Os demais fatores foram avaliados quanto à disponibilidade de dados e viabilidade de utilização.

Desta forma, as variáveis identificadas como tendo potencial de emprego são: volume de tráfego, porcentagem de veículos pesados, velocidade máxima regulamentada, uso do solo, tipo de divisão central, tipo de interseção, número de faixas, largura de faixa, largura do acostamento, iluminação, superfície do pavimento, sinalização horizontal, alinhamento horizontal e alinhamento vertical.

Dentre estas, nem todas puderam ser efetivamente utilizadas. A contagem classificada de veículos é realizada apenas nas praças de pedágios, o que inviabiliza o uso da porcentagem de veículos pesados. A sinalização horizontal, inicialmente pensada para ser expressa em termos de retrorrefletividade, foi excluída do rol de variáveis, dada a indisponibilidade de dados em todos os anos e em todos os trechos. Em termos de alinhamento horizontal e vertical, devido à restrição de dados, apenas o raio de curva horizontal e inclinação média (ascendente ou descendente) do segmento serão utilizados. A largura de faixa foi indicada como constante em toda via e a medição via imagens de satélite não permitiram obter medidas precisas. Já o tipo de interseção foi tratado mediante número de acessos e saídas da rodovia, dadas as características geométricas. Somadas a estas, outras variáveis foram justificadamente incorporadas.

Inicialmente, a partir da análise dos dados disponíveis e potencial relação com a ocorrência de acidentes, foram definidas cerca de 30 variáveis. Em seguida, numa análise refinada algumas variáveis foram excluídas e ainda, após os primeiros resultados da modelagem, mais variáveis foram excluídas e outras ajustadas. Atributos como deflexão característica máxima do pavimento e índice de saturação de tráfego, por exemplo, poderiam ser interessantes na investigação da ocorrência de acidentes; no entanto, devido a limitações na coleta dos dados tiveram de ser desprezados. Como mencionado anteriormente, a definição e redefinição de

variáveis é parte do processo de interação entre as etapas de preparação dos dados e a modelagem.

A seguir apresenta-se a descrição de rol final de variáveis utilizadas na modelagem e aspectos da coleta de dados. As fontes dos dados estão indicadas no item 4.3.2.

(i) Características Geométricas

- *Trecho da via*

a) Proporção do comprimento de reta no segmento

Cafiso *et al.* (2010) afirmam ser importante considerar a porcentagem de reta no comprimento do segmento, uma vez que elas podem induzir a altas velocidades e contribuir para a ocorrência e severidade dos acidentes. Identificados os pontos de início e final de curvas, tal variável é calculada conforme Equação 4.1.

$$PCR = \frac{\sum (l_i)}{CS} \quad (4.1)$$

Em que:

$PCR$  é a proporção do comprimento de reta no segmento;

$l_i$  é o comprimento da reta  $i$  (km);

$CS$  é o comprimento do segmento (km); e

$i$  é cada sub-trecho reto dentro do segmento ( $i = 1, 2, \dots n$ ).

b) Proporção do comprimento de curva no segmento

Cafiso *et al.* (2010) também acredita ser importante considerar a razão do comprimento de curva no comprimento total do segmento, conforme Equação 4.2.

$$PCC = \frac{\sum (l_j)}{CS} \quad (4.2)$$

Em que:

$PCC$  é a proporção do comprimento de curvas no segmento;

$l_j$  é o comprimento da curva  $j$  (km);

$CS$  é o comprimento do segmento (km); e

$j$  é cada curva inserida no segmento ( $i = 1, 2, \dots n$ ).

### c) Alinhamentos

Glennon (1987) investigou a influência dos elementos do alinhamento (vertical e horizontal) na ocorrência de acidentes. O autor relata que é comum curvas apresentarem taxas de acidente superiores aos trechos em tangente, indicando a necessidade de incorporação e investigação dos elementos de alinhamentos horizontal e vertical na análise de acidente. Os trabalhos de Madalozo (2003), Chang (2005), Chang e Chen (2005), Das e Abdel-Aty (2011), Çodur e Tortum (2015) e Zeng *et al.* (2016a), nos quais são utilizadas variáveis relativas ao alinhamento geométrico, reiteram a importância de consideração destes fatores.

#### o Inverso do raio das curvas horizontais

Consoante a disponibilidade de dados, em termos de curvatura horizontal será utilizado o inverso do raio de curva. O raio das curvas horizontais está associado à velocidade operacional da via ( $V_{85}$ ) (FITZPATRICK *et al.*, 2000) e sua variação relacionada com o número potencial de acidentes nas curvas horizontais e o limite desejável de segurança viária (HAUER, 1999; MADALOZO, 2003).

O valor da variável foi calculado através da média aritmética do inverso dos raios de curvas presentes no segmento, conforme Equação 4.3.

$$IRH = \frac{\sum_{i=1}^n \frac{1}{RH_i}}{n} \quad (4.3)$$

Em que:

$IRH$  é a média do inverso do raio das curvas horizontais do segmento ( $m^{-1}$ );

$RH_i$  é o raio da curva horizontal  $i$  (m);

$n$  é o número de curvas horizontais no segmento; e  
 $i$  é cada curva horizontal ao longo do segmento ( $i = 1, 2, \dots n$ ).

o Inclinação

Em termos de alinhamento vertical será utilizada a inclinação de rampa da rodovia. O projeto do greide também deve objetivar a fluência e conforto do traçado. Desta forma, as rampas devem ser tão contínuas quanto possível, evitando-se frequentes alterações nos valores de inclinação. A considerar os diferentes impactos do sentido da inclinação (positiva ou negativa), foram utilizadas como variáveis a inclinação média das rampas ascendentes (*IMA*) e inclinação média das rampas descendentes (*IMD*) no segmento, obtidas pela média ponderada das inclinações, conforme Equações 4.4 e 4.5.

$$IMA = \frac{\sum_{i=1}^n (l_i \cdot i_i)}{\sum_{i=1}^n l_i} \quad (4.4)$$

$$IMD = \frac{\sum_{j=1}^m |(l_j \cdot i_j)|}{\sum_{j=1}^m l_j} \quad (4.5)$$

Em que:

*IMA* é a inclinação média das rampas ascendentes do segmento (%);

*IMD* é a inclinação média das rampas descendentes do segmento (%);

$l_i$  é o comprimento do sub-trecho  $i$  de rampa ascendente (m);

$l_j$  é o comprimento do sub-trecho  $j$  de rampa descendente (m);

$i_i$  é a inclinação do sub-trecho  $i$  de rampa ascendente (%);

$i_j$  é a inclinação do sub-trecho  $j$  (%) de rampa descendente (%);

$i$  é cada rampa ascendente ao longo do segmento ( $i = 1, 2, \dots n$ ); e

$j$  é cada rampa descendente ao longo do segmento ( $j = 1, 2, \dots m$ ).

- Número de acessos e saídas

Os pontos de acesso e saída de uma rodovia causam perturbações no tráfego, o que contribui para a ocorrência de acidentes. Para avaliação deste efeito, tendo em conta a existência de interseções em desnível e que a dinâmica de ingresso ou egresso na rodovia pode ser diferente, são consideradas duas variáveis: número de acessos e número de saídas.

- *Seção transversal*

O estudo de Glennon (1987) também indicou o potencial de influência dos elementos da seção transversal da rodovia à ocorrência de acidentes. Tais elementos podem influenciar a visão transversal do condutor, conforto e percepção de risco. Os trabalhos de Sohn e Lee (2003), Madalozo (2003), Chang e Chen (2005), Chang e Wang (2006), Xie *et al.* (2007), Li *et al.* (2008), Das e Abdel-Aty (2010), Das e Abdel-Aty (2011), Oña *et al.* (2011), Oña *et al.* (2013a), Oña *et al.* (2013b), Çodur e Tortum (2015), Chen *et al.* (2016) e Zeng *et al.* (2016a), nos quais são utilizadas variáveis relativas a seção transversal da rodovia, reforçam a relevância de incorporação destes fatores.

- a) Divisão da via

O tipo de divisão da via pode influenciar tanto na ocorrência de acidente quanto na sua severidade. As pistas da rodovia analisada podem ser separadas por barreira ou canteiro central. Além disso, também foi incorporada à variável de largura do canteiro central.

- b) Número de faixas

O número de faixas que está relacionado à capacidade, conforto e manobras na via, também foi considerado.

- c) Largura do acostamento

Costa (2013) afirma que o acostamento além de influenciar a visão transversal do condutor, tem por finalidade limitar as consequências dos acidentes. Conforme Odgen

(1996), o acostamento é caracterizado como uma área de recuperação aos veículos desgovernados e garante o afastamento em relação aos objetos e estruturas existentes nas laterais da rodovia. Essa variável foi calculada através da média aritmética da largura do acostamento ao longo do segmento.

## (ii) Características Operacionais

As condições de operação das rodovias estão fortemente associadas à segurança viária, uma vez que influenciam a trajetória dos veículos e o comportamento dos condutores. Um indicativo disso é o uso de condições operacionais como fatores de risco em diversos estudos, dos quais destacam-se: Abdel-Aty e Abdelwahab (2004), Chang e Wang (2006), Das e Abdel-Aty (2010), Das e Abdel-Aty (2011), Oña *et al.* (2011), Oña *et al.* (2013a), Oña *et al.* (2013b), Alikhani *et al.* (2013), Zeng e Huang (2014), Chen *et al.* (2016) e Zeng *et al.* (2016b).

### a) Volume de tráfego

O volume de tráfego diário médio anual (*VDMA*) é um fundamental fator de exposição ao risco de acidentes de trânsito em elementos viários. Os valores mensais de *VDMA*, calculados ao longo de 44 trechos em cada sentido, foram utilizados para caracterizar, em termos médios, o tráfego nos segmentos. É obtido pela média ponderada nos casos em que o segmento possua extensões com diferentes *VDMA*.

### b) Velocidade máxima regulamentada

A velocidade é, indiscutivelmente, um fator associado à ocorrência de acidente e sua severidade resultante. A partir de 115 estudos, contendo 526 estimativas de efeito, Elvik (2009) buscou analisar a relação entre a velocidade e a segurança viária. As conclusões são de que a velocidade permanece como importante fator de risco, sendo o mais significativo tanto para a ocorrência de acidentes como para severidade. O autor acredita que a velocidade é o maior dos problemas em segurança viária dos países motorizados e defende a necessidade de imposição de limites de velocidade. Devido a limitação de dados, será utilizada como variável apenas a velocidade máxima regulamentada, em km/h.



c) Controle de tráfego

Também será investigada a influência de controladores eletrônicos de velocidade para ocorrência dos acidentes, por meio da indicação do número destes dispositivos no segmento.

d) Uso do solo

A composição da área envolvente dos segmentos em estudo parece impactar na ocorrência de acidentes. Para Ivan *et al.* (2000) e Bindra *et al.* (2009), o uso do solo é um fator importante para previsão de acidentes e merece investigação. Para este efeito, foi utilizada a classificação do DNIT para os trechos urbanos e rurais da rodovia.

e) Iluminação

Diversos estudos investigaram a relação entre iluminação da rodovia e a ocorrência de acidentes (ICI, 1992; ELVIK, 1995; WANVIK, 2009), se mostrando um fator importante para a redução de acidentes e severidade resultante. Diante disso, foi utilizada uma variável que expressa a proporção de iluminação no segmento, conforme Equação 4.6.

$$PI_{ilum,i} = \sum_{i=0}^n \frac{l_{ilum,i}}{CS} \quad (4.6)$$

Em que:

$PI_{ilum,i}$  é a proporção do comprimento iluminado no segmento  $i$ ;

$l_{ilum}$  é o comprimento iluminado  $i$  (m);

$CS$  é o comprimento do segmento (m); e

$i$  é cada sub-trecho iluminado dentro do segmento ( $i = 0, 1, 2, \dots n$ ).

### (iii) Características do Pavimento

Balbo (2007) defende que o pavimento deve se prestar à melhoria operacional do tráfego, fornecendo uma superfície mais regular (garantia de melhor conforto no deslocamento do veículo), mais aderente (garantia de maior segurança em condições de pista úmida ou molhada) e menos ruidosa.

Neste sentido, Tighe *et al.* (2000) afirma que existem diversos fatores associados ao pavimento que podem influenciar na segurança viária, destacando: geometria do pavimento, rugosidade, propriedades dos materiais de pavimentação, regularidade da superfície, textura da superfície, sinalização. O autor defende a incorporação de critérios de segurança viária no sistema de gerência de pavimentos, já que para ele o monitoramento e manutenção de uma ou mais características do pavimento podem contribuir para a redução de acidentes. De forma reiterada, Bernucci *et al.* (2008) também afirmam que a segurança nas rodovias engloba diversos aspectos do pavimento.

Os trabalhos de Chang e Wang (2006), Delen *et al.* (2006), Das e Abdel-Aty (2010), Bella *et al.* (2011), Das e Abdel-Aty (2011), Oña *et al.* (2011), Oña *et al.* (2013a), Oña *et al.* (2013b), Alikhani *et al.* (2013), Zeng e Huang (2014), Kwon *et al.* (2015), Chen *et al.* (2016), nos quais são utilizadas variáveis explicativas associadas ao pavimento da rodovia, corroboram para a utilização destes fatores. As condições de operação das rodovias estão fortemente associadas à segurança viária, uma vez que influenciam a trajetória dos veículos e o comportamento dos condutores.

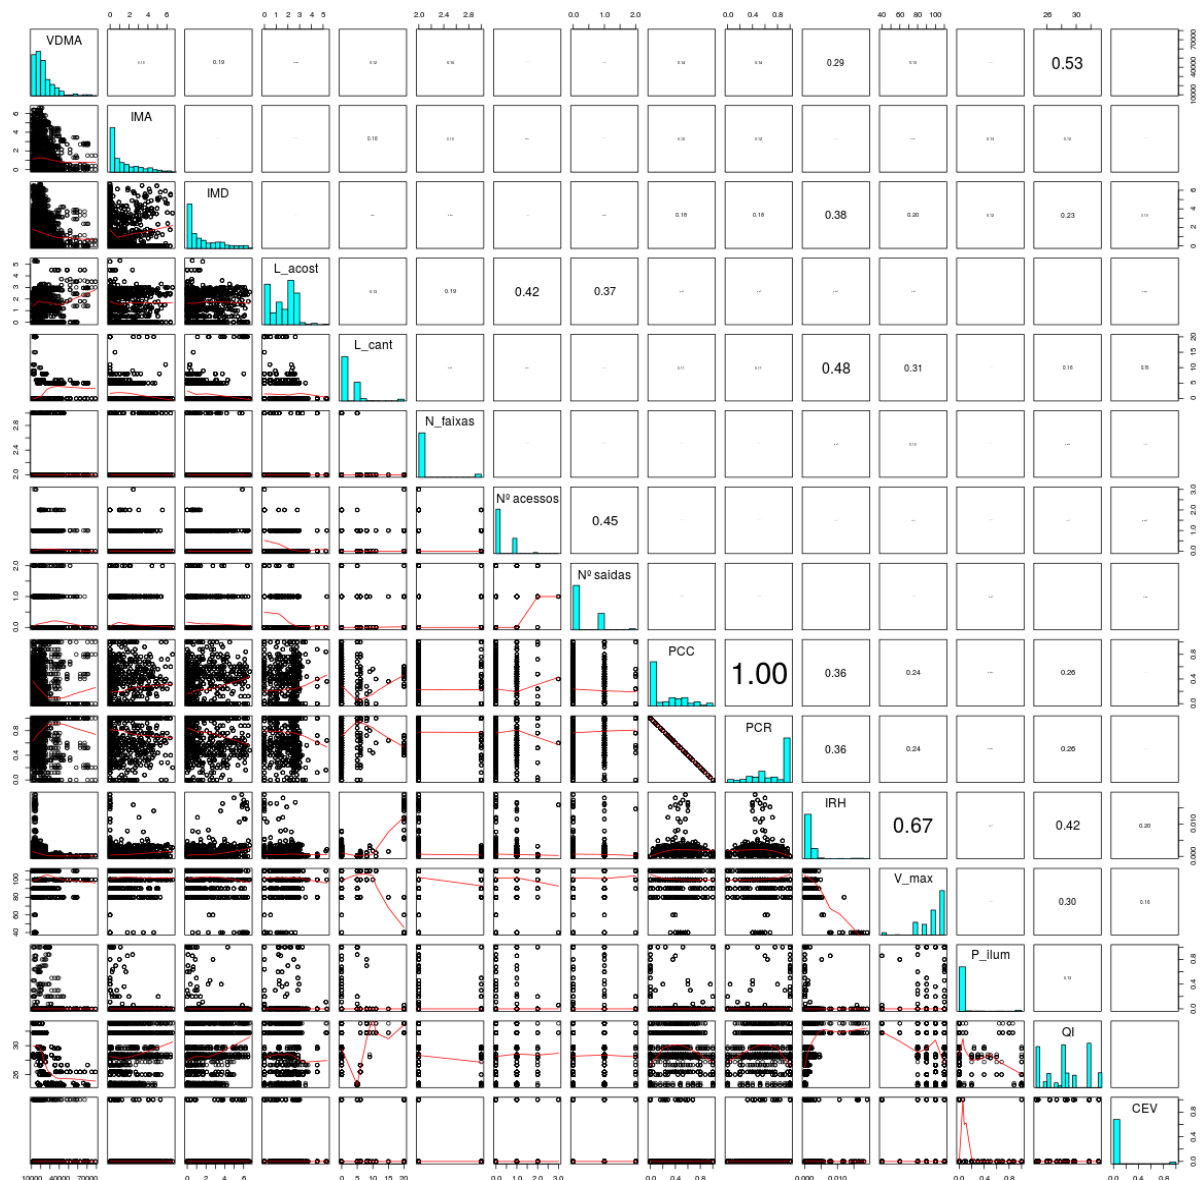
Embora existissem outras características do pavimento, dadas as limitações da forma de apresentação dessas variáveis, apenas o quociente de irregularidade do pavimento foi adotado. Segundo DNER (1985) e DNER (1986a), irregularidade é o desvio da superfície da rodovia em relação a um plano de referência, que afeta a dinâmica dos veículos, a qualidade de rolamento e as cargas dinâmicas sobre a via. O *QI* (Quociente de Irregularidade), procedimento normalizado pelo DNIT, é o índice representativo da irregularidade da superfície do pavimento, expresso em contagens por quilômetro (DNIT, 2006).

Tem objetivo análogo ao IRI (*International Roughness Index*) e é um parâmetro essencial na gerência de pavimento, que também assume importância associada ao conforto e segurança viária (BARELLA, 2008). Trata-se de um parâmetro mais objetivo e que reflete também efeitos de outros indicadores, como o Índice de Gravidade Global (IGG). Uma rodovia degradada (IGG alto) a ponto de interferir na segurança também terá maior *QI*. Já uma rodovia sem degradação visível (IGG baixo), mas com irregularidades no pavimento, não é adequadamente modelada pelo IGG. Assim, o *QI* foi o atributo que apresentou melhor relação com os acidentes.

#### (iv) Correlação entre variáveis

Embora não seja uma limitação para o emprego de técnicas de AM (LERAY & GALLINARI, 1999; MAY *et al.*, 2011), procedeu-se à avaliação da correlação entre todas as variáveis explicativas, por meio da matriz de correlação, como apresentado na Figura 4.4. Por questões de espaço, estão sumarizados nessa figura os resultados da Pista Norte, no período 2011 a 2014 para segmentos de 500 m. As constatações, no entanto, são similares para todos os demais casos.

Do lado direito da figura estão indicados os coeficientes de correlação, enquanto que do lado esquerdo os correspondentes gráficos de dispersão estão plotados; e ainda, na diagonal apresenta-se o histograma de cada variável explanatória. Além da correlação existente entre *PCC* e *PCR*, que são variáveis complementares, verificou-se correlação superior a 0,50 apenas entre *QI* e *VDMA* e, *IRH* e *V\_max*, como esperado. Tais valores não sinalizam forte correlação nem requerem a escolha e exclusão de variável, motivo pelo qual manteve-se o conjunto de variáveis apresentado. Dessa forma fica garantido que, quando da comparação de resultados os modelos estatísticos, mais sensíveis à correlação entre variáveis, não tenham sido penalizados frente aos modelos de RNA.



**Figura 4.4** – Matriz de correlação entre as variáveis explicativas, para Pista Norte, período 2011-2014

#### (v) Priorização de Variáveis

A priorização de variáveis no processo de modelagem de acidentes pode contribuir para otimização de recursos e indicação de quais dados são prioritários para coleta. Conforme sugerido por Saha *et al.* (2015) e Saha *et al.* (2016), é relevante conduzir investigações sobre a possibilidade de simplificar os requisitos de dados a serem coletados, observando ainda a minimização dos impactos disso para a qualidade desejável dos modelos. Dessa forma, procedeu-se inicialmente a três abordagens: aplicação de técnicas de agrupamento de árvores de decisão (*Random Forest, Boosted Trees*) para priorização inicial e posterior modelagem com

uso de RNA; utilização direta de RNA para priorização e modelagem; emprego de Análise de Componentes Principais (ACP) para tentativa de redução de dimensionalidade.

Como resultados da primeira abordagem, os melhores modelos desenvolvidos (com número reduzido de variáveis) tiveram desempenho inferior ao modelo geral de referência (com todas as variáveis). Diante de tais resultados e, valendo-se da afirmação de Nisbet *et al.* (2018), os quais dizem ser interessante utilizar os fatores de importância das variáveis de entrada (provenientes da análise de sensibilidade) como estratégia para determinar o melhor conjunto de variáveis a serem incluídas em um modelo, decidiu-se por proceder a modelagem com RNA a partir de todas as variáveis executando-se sucessivas exclusões de variáveis. Nessa segunda abordagem, os erros e a análise de resíduos permitiram verificar que os modelos, assim como na abordagem inicial, ajustam-se melhor quando da utilização de quase todas as variáveis disponíveis inicialmente.

Por fim, aplicando ACP à base de dados verificou-se um lento incremento da variância cumulativa das componentes. Dessa maneira, a redução para um pequeno número de componentes principais, mantendo a maior parte da variância explicada não foi viável. Além disso, a criação de componentes principais dificultaria a exploração dos efeitos individuais de cada variável.

Em todas as abordagens para redução de dimensionalidade do problema não fica evidente qual exclusão de variáveis poderia ser realizada preservando-se ao mesmo tempo o desempenho próximo ao melhor possível. Diferente de modelos estatísticos, as técnicas de Aprendizado de Máquina identificam padrões não explícitos, o que pode sugerir que quanto mais dados (e informações) são utilizadas, melhor é a descoberta de conhecimento do problema (ajuste do modelo). Diante dos resultados dos experimentos, optou-se seguramente por utilizar o conjunto completo de variáveis para a modelagem.

#### **4.3.2 Construção das Bases de Dados**

As variáveis foram calculadas mediante uso de informações constantes no RETOFF (Relatórios de Monitoração e Nível de Serviço) levantamento do traçado da rodovia e utilização de imagens de satélite. Na Tabela 4.3 estão apresentadas as variáveis utilizadas no processo de modelagem.

**Tabela 4.3** - Descrição das variáveis explicativas e variáveis dependentes

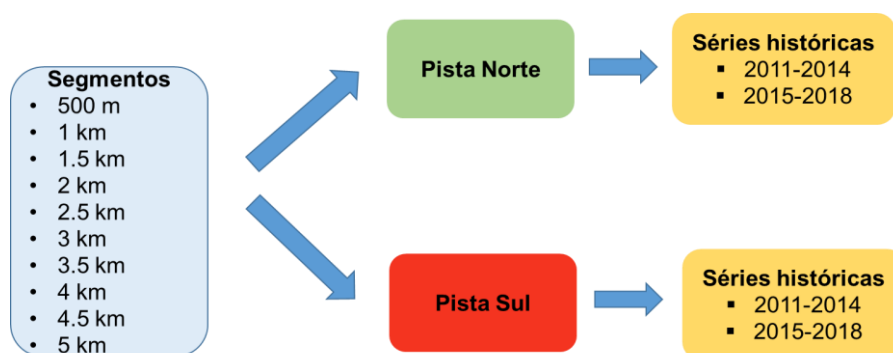
<b>Variáveis dependentes</b>			
<b>Variável</b>	<b>Descrição</b>	<b>Natureza</b>	<b>Unidade/Resposta</b>
<i>NASV</i>	Número de acidentes sem vítimas/segmento	Numérica	Adimensional
<i>NACV</i>	Número de acidentes com vítimas/segmento	Numérica	Adimensional
<i>NACM</i>	Número de acidentes com vítimas fatais/segmento	Numérica	Adimensional
<b>Variáveis independentes</b>			
<b>Variável</b>	<b>Descrição</b>	<b>Natureza</b>	
<i>PCR</i>	Proporção do comprimento de reta no segmento	Numérica	Adimensional
<i>PCC</i>	Proporção do comprimento de curva no segmento	Numérica	Adimensional
<i>IRH</i>	Inverso do raio das curvas horizontais	Numérica	$m^{-1}$
<i>IMA</i>	Inclinação média das rampas ascendentes	Numérica	%
<i>IMD</i>	Inclinação média das rampas descendentes	Numérica	%
<i>N_aceessos</i>	Número de acessos no segmento	Numérica	Adimensional
<i>N_saídas</i>	Número de saídas no segmento	Numérica	Adimensional
<i>Div_pista</i>	Tipo de divisão de pista	Catagórica	Barreira, Canteiro central
<i>L_cant</i>	Largura média do canteiro central	Numérica	$m$
<i>L_acost</i>	Largura média do acostamento	Numérica	$m$
<i>N_faixas</i>	Número de faixas	Numérica	Adimensional
<i>VDMA</i>	Volume Diário Médio Anual	Numérica	$veíc/dia$
<i>V_max</i>	Velocidade máxima regulamentada	Numérica	$km/h$
<i>CEV</i>	Controlador eletrônico de velocidade	Numérica	Adimensional
<i>Uso_solo</i>	Uso do solo	Catagórica	Urbano, Rural
<i>P_ilum</i>	Proporção de iluminação no segmento	Numérica	Adimensional
<i>QI</i>	Quociente de irregularidade	Numérica	$contagens/km$

As variáveis de inclinação média positiva e negativa do segmento, proporção de curva e reta no segmento, média do inverso do raio das curvas horizontais foram determinadas a partir do levantamento do traçado da rodovia, fornecido pela ANTT. Os pontos de acesso e saída, tipo de divisão de pista, largura média do canteiro, largura média do acostamento e número de faixas foram calculados a partir de imagens de satélite. A velocidade máxima regulamentada foi determinada a partir do RETOFF e do Relatório de Monitoração, confirmada via imagens de satélite. O número de acidentes, *VDMA*, controladores eletrônicos de velocidade e *QI* foram calculados com base nos RETOFFs mensais. Por fim, o uso do solo foi obtido através do sistema SIOR do DNIT.

Todos os segmentos foram caracterizados pelos valores médios (ou totais, quando o caso) à exceção do tipo de divisão de pista, número de faixas, velocidade máxima regulamentada, uso do solo e nível de serviço. Nos casos dessas variáveis, utilizou-se a característica predominante

no segmento. Por exemplo, um segmento com 80% de sua extensão inserida em ambiente rural é caracterizado como possuindo uso do solo do tipo rural.

Devido à mudança do procedimento de registro de acidentes sem vítimas, como já mencionado na seção 4.2, fez-se a divisão da série histórica analisada em dois períodos: 2011 a 2014 e 2015 a 2018, de modo a garantir o mais coerência e qualidade de ajuste dos modelos. Após a caracterização dos segmentos foram construídas as 40 bases de dados, como apresentado na Figura 4.5.



**Figura 4.5 - Composição das bases de dados**

#### 4.4. ESTATÍSTICA DESCRITIVA DOS SEGMENTOS

Na Tabela 4.4 estão apresentados os números de segmentos por extensão e o número de observações para os dois períodos de análise considerados.

**Tabela 4.4 - Distribuição do número de segmentos e observações**

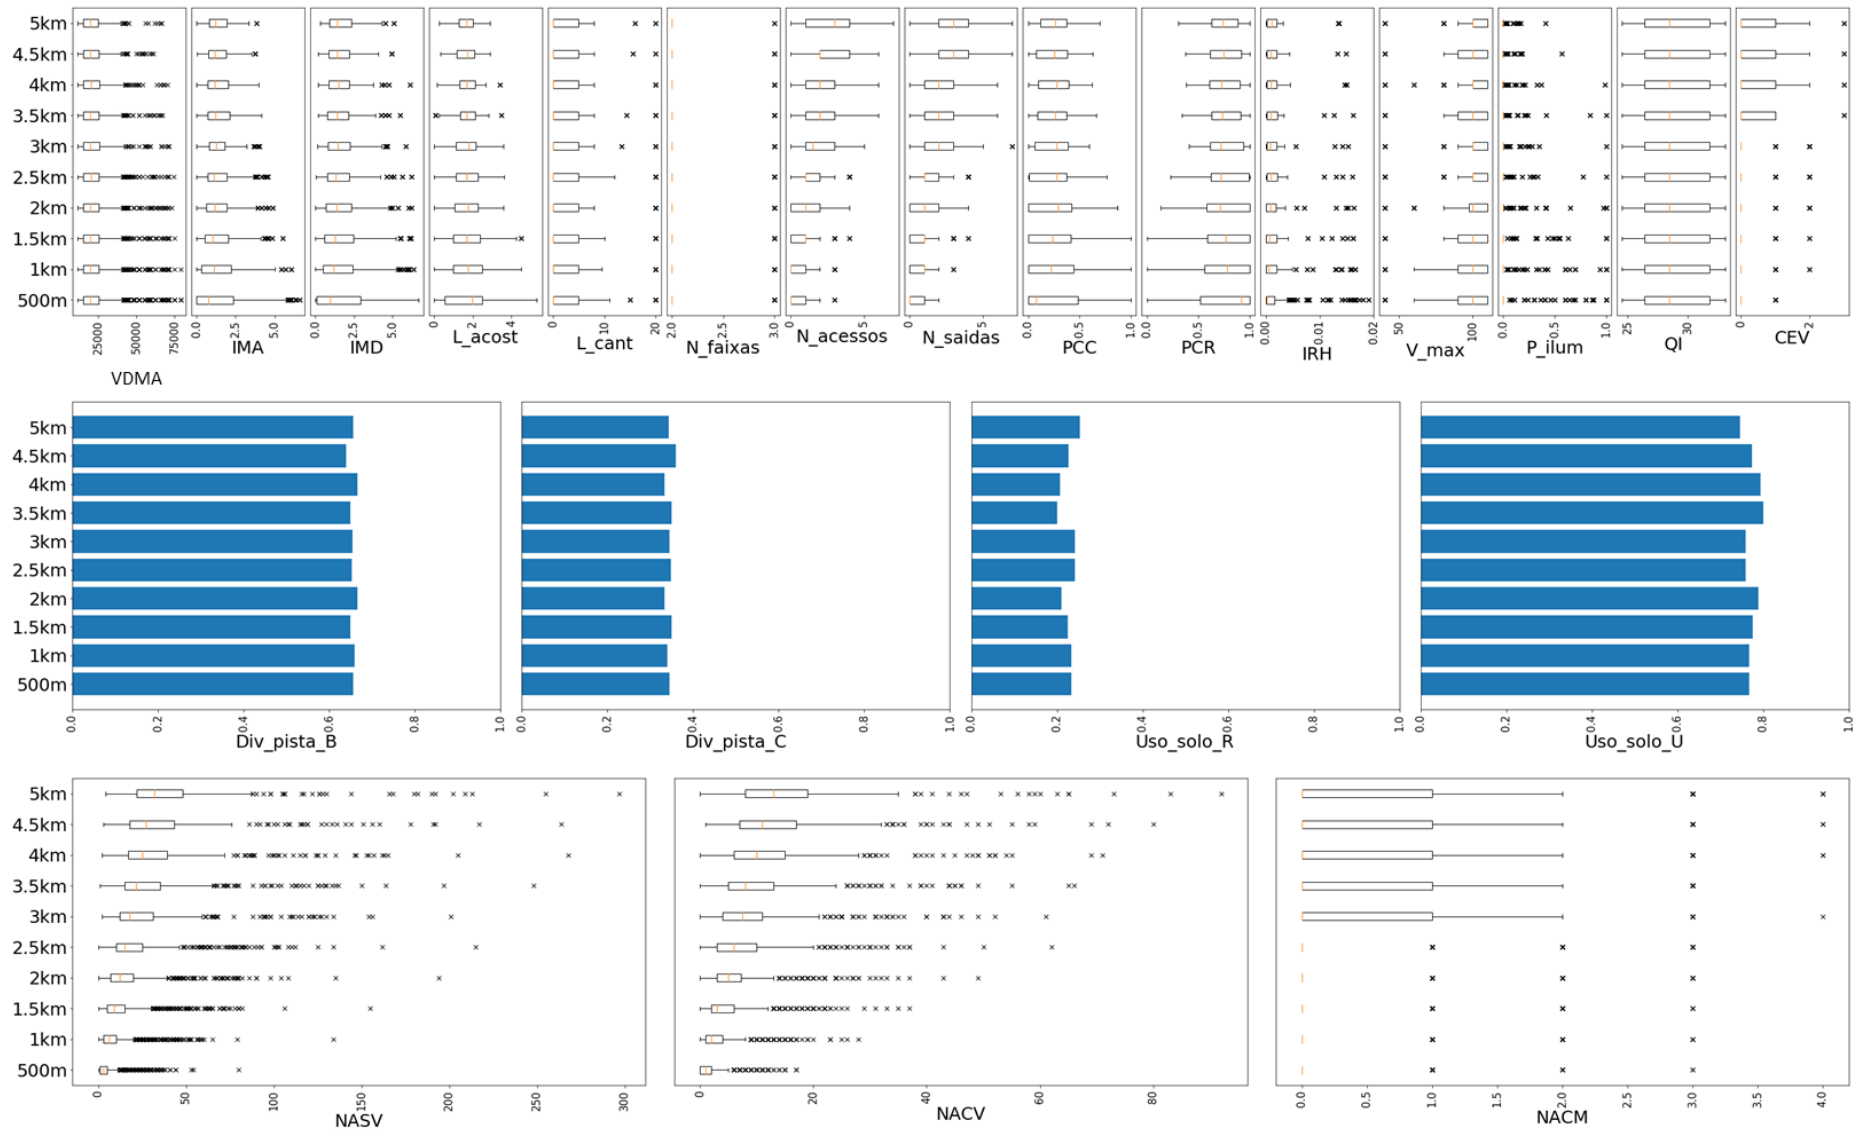
Extensão do segmento	PN		PS	
	Nº de segmentos	Nº de observações 2011-2014 / 2015-2018	Nº de segmentos	Nº de observações 2011-2014 / 2015-2018
<b>500 m</b>	734	2936 / 2936	737	2936 / 2936
<b>1 km</b>	364	1456 / 1456	365	1460 / 1460
<b>1,5 km</b>	240	960 / 960	241	964 / 964
<b>2 km</b>	180	720 / 720	179	716 / 716
<b>2,5 km</b>	141	564 / 564	142	568 / 568
<b>3 km</b>	116	464 / 464	116	464 / 464
<b>3,5 km</b>	100	400 / 400	101	404 / 404
<b>4 km</b>	87	348 / 348	87	348 / 348
<b>4,5 km</b>	75	300 / 300	76	304 / 304
<b>5 km</b>	67	268 / 268	67	268 / 268

As Figuras 4.6, 4.7, 4.8 e 4.9 sintetizam graficamente os resultados da estatística descritiva das bases de dados. De forma geral, o valor médio das variáveis não sofre grandes variações nas diferentes extensões de segmento, nota-se, apenas que  $N_{acessos}$ ,  $N_{saídas}$  e  $CEV$  tem média sensivelmente maior nos segmentos mais longos. Isso porque, diferente das demais variáveis, que são medidas pela média dos valores e, portanto, menos sensíveis a extensão do segmento, essas três variáveis têm em conta o número acessos, saídas e de controladores eletrônicos de velocidade em cada segmento, sendo tais valores absolutos maiores quanto mais elevada for a extensão do segmento. Pelo mesmo motivo, igual efeito é notado para o Número de acidentes sem vítimas ( $NASV$ ), Número de acidentes com vítimas ( $NACV$ ) e Número de acidentes com mortes ( $NACM$ ). Outra observação geral é que, como esperado, o número e concentração de valores discrepantes de cada variável diminui à medida que os segmentos se tornam mais extensos.

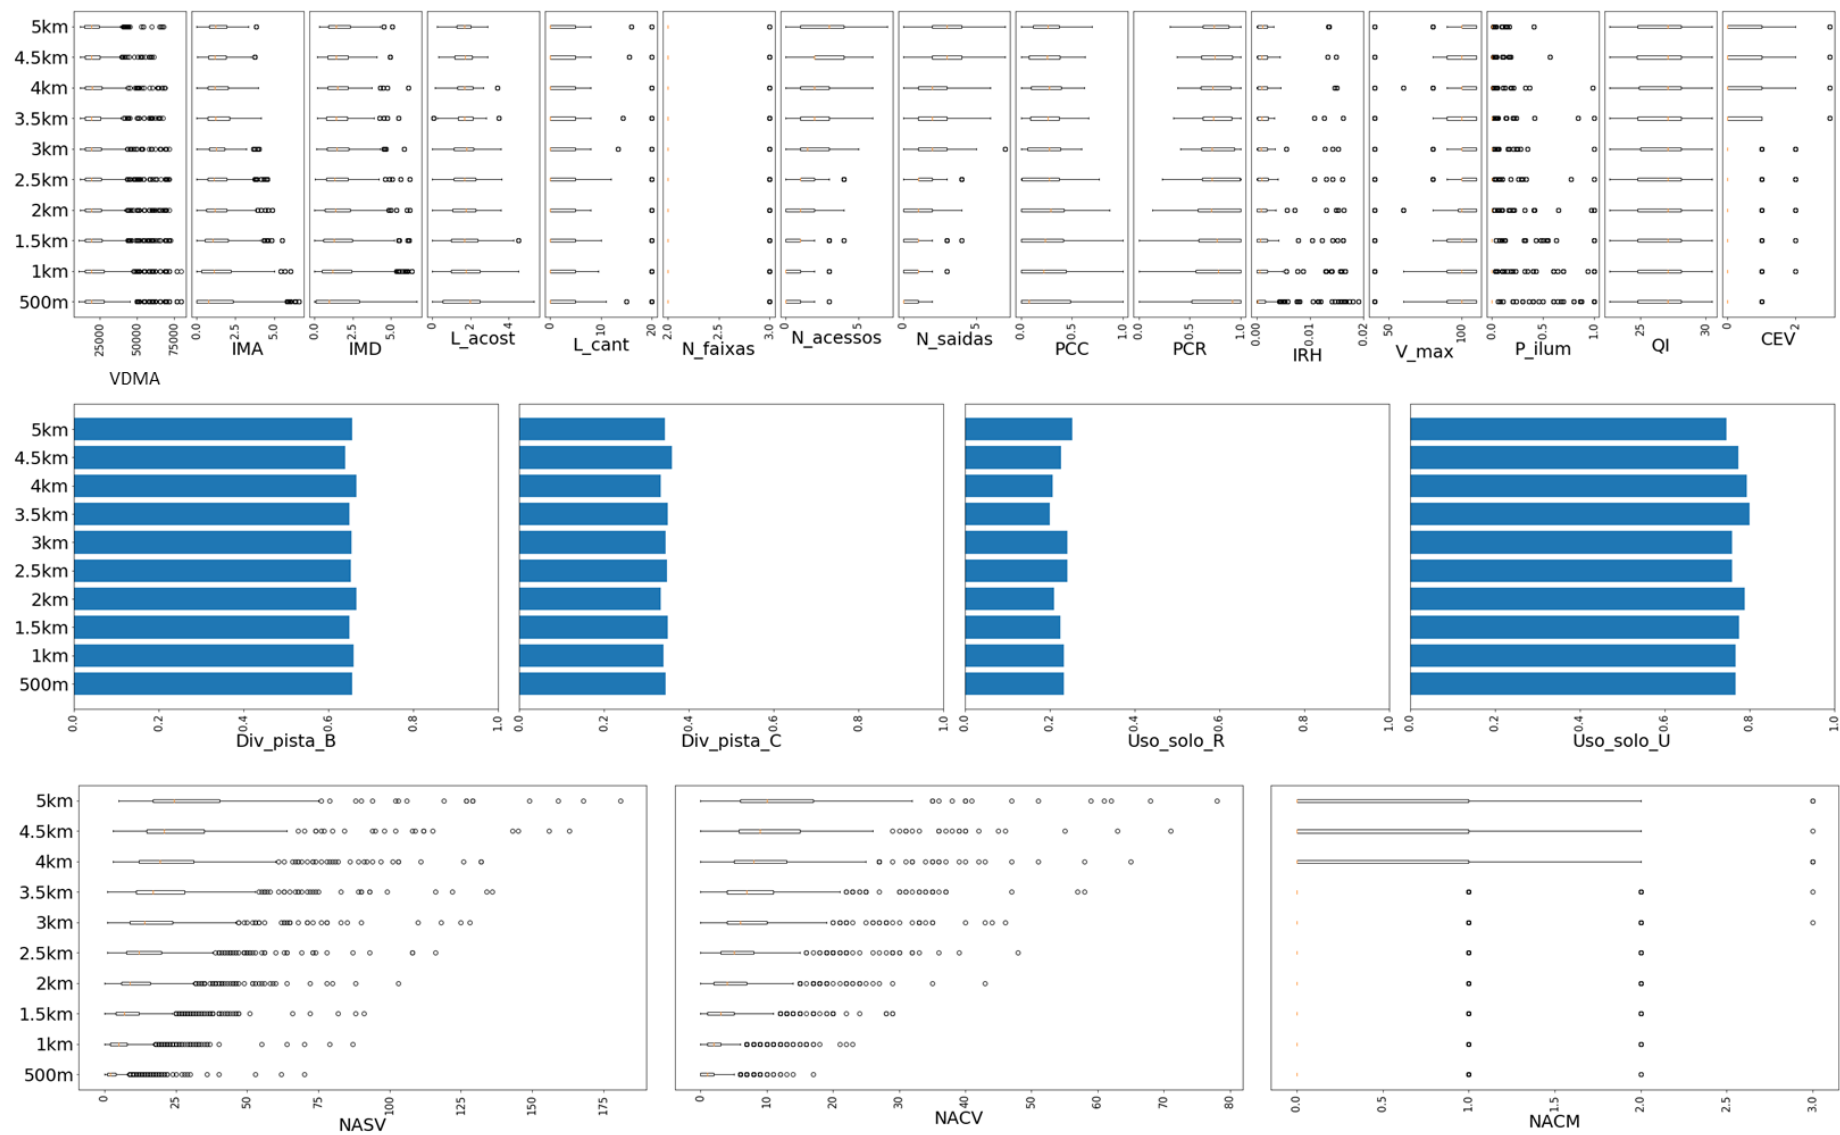
No trecho analisado, que liga as cidades de São Paulo e Rio de Janeiro, nota-se predominância dos segmentos em ambiente urbano, dada a existência de diversas cidades ao longo desse percurso. Mais da metade do trecho tem pistas de tráfego separadas por barreiras rígidas tipo *New Jersey*, enquanto os demais trechos possuem canteiro central de até 20 m de largura, com largura média de 2,3 m. Quanto ao acostamento, a largura média em ambas as pistas é de cerca de 1,60 m. Isso porque cerca de 70% dos segmentos possui largura de acostamento inferior a 2,50 m, que é o valor recomendado pelo DNIT (1999) para esse tipo de rodovia. O número de faixas de rodagem é tipicamente dois por sentido, ocorrendo três faixas apenas em cerca de 10% dos segmentos.

A velocidade máxima regulamentada varia entre 40 km/h e 110 km/h, sendo que o valor mínimo ocorre apenas em alguns trechos de relevo montanhoso, enquanto que os valores típicos de velocidade máxima são 100 km/h e 110 km/h. Nos mesmos trechos de região montanhosa, são registrados os valores máximos de inclinação de rampa ascendente e descendente, enquanto que a inclinação média de rampa no trecho total analisado está em torno de 1,5%. Tem-se ainda que, em média, 75% do comprimento dos segmentos é de reta enquanto que o restante é caracterizado por curvas horizontais.

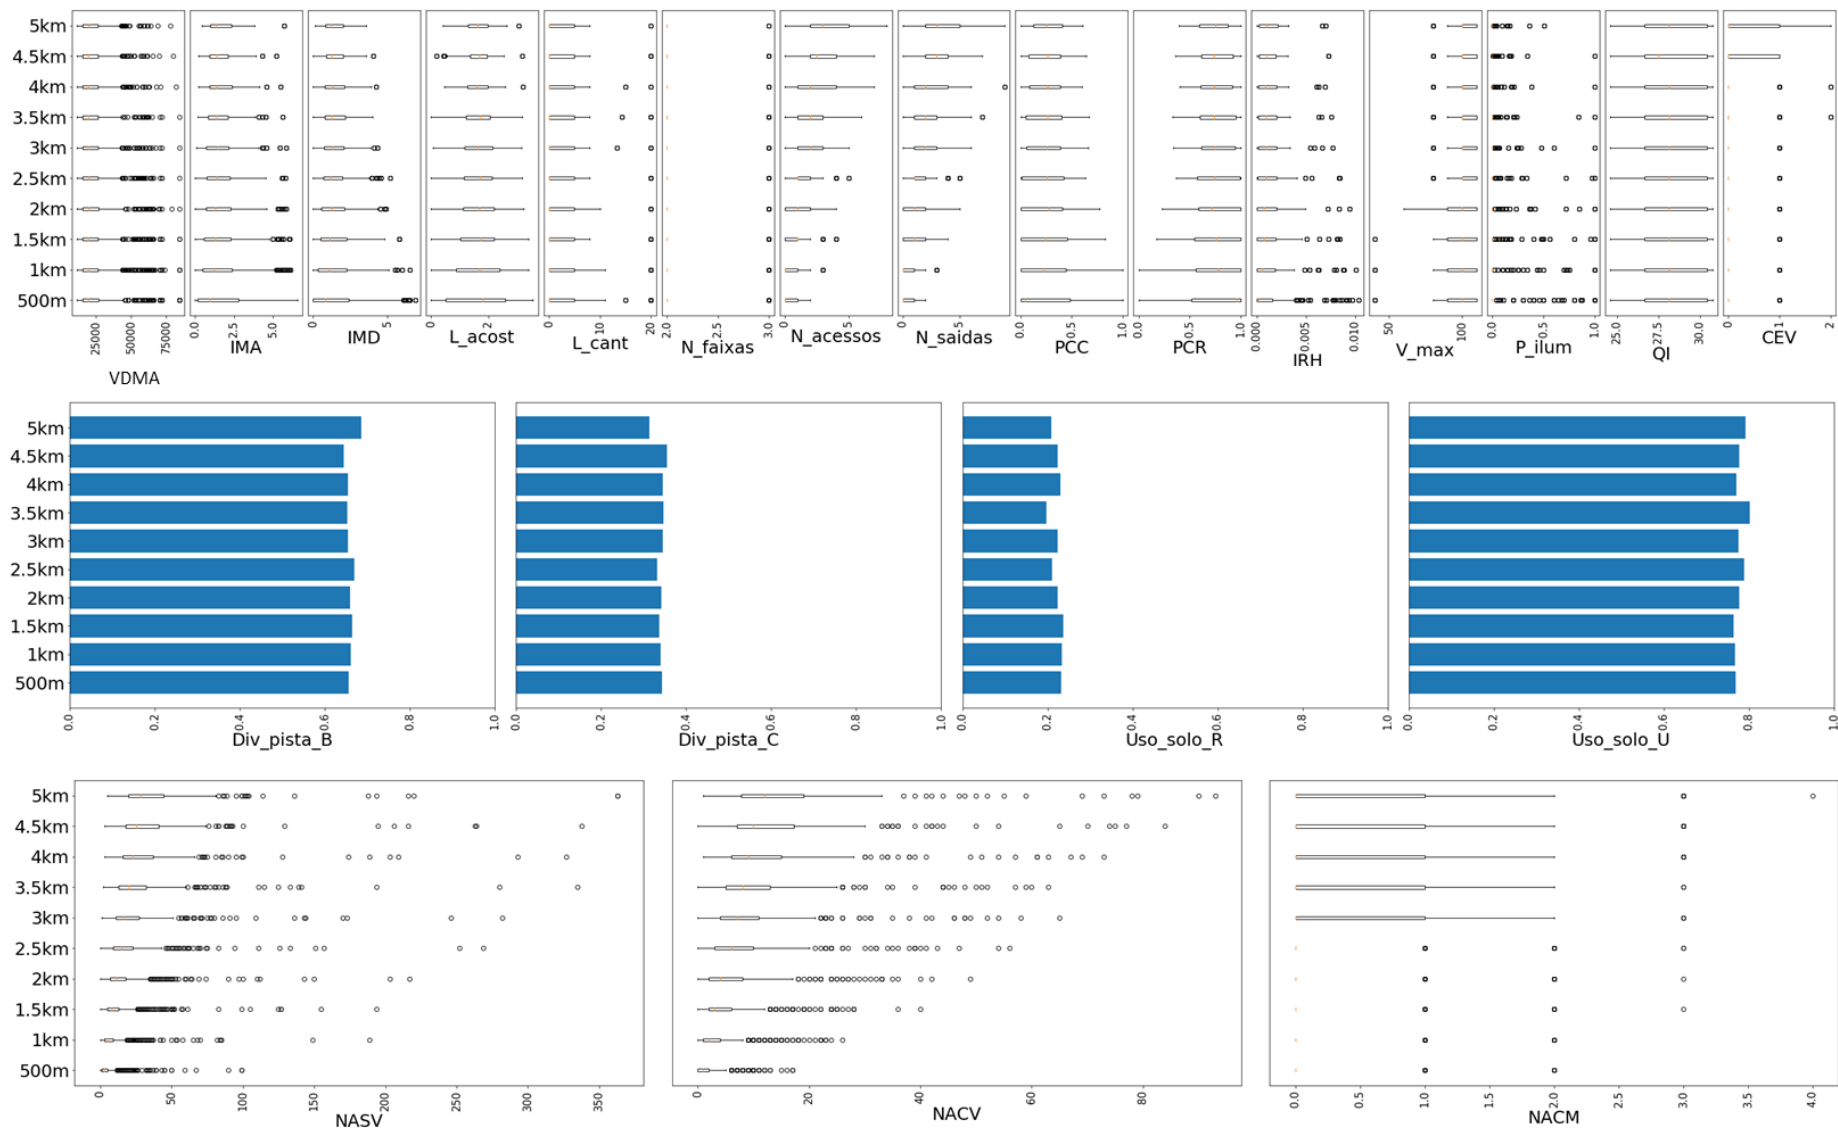




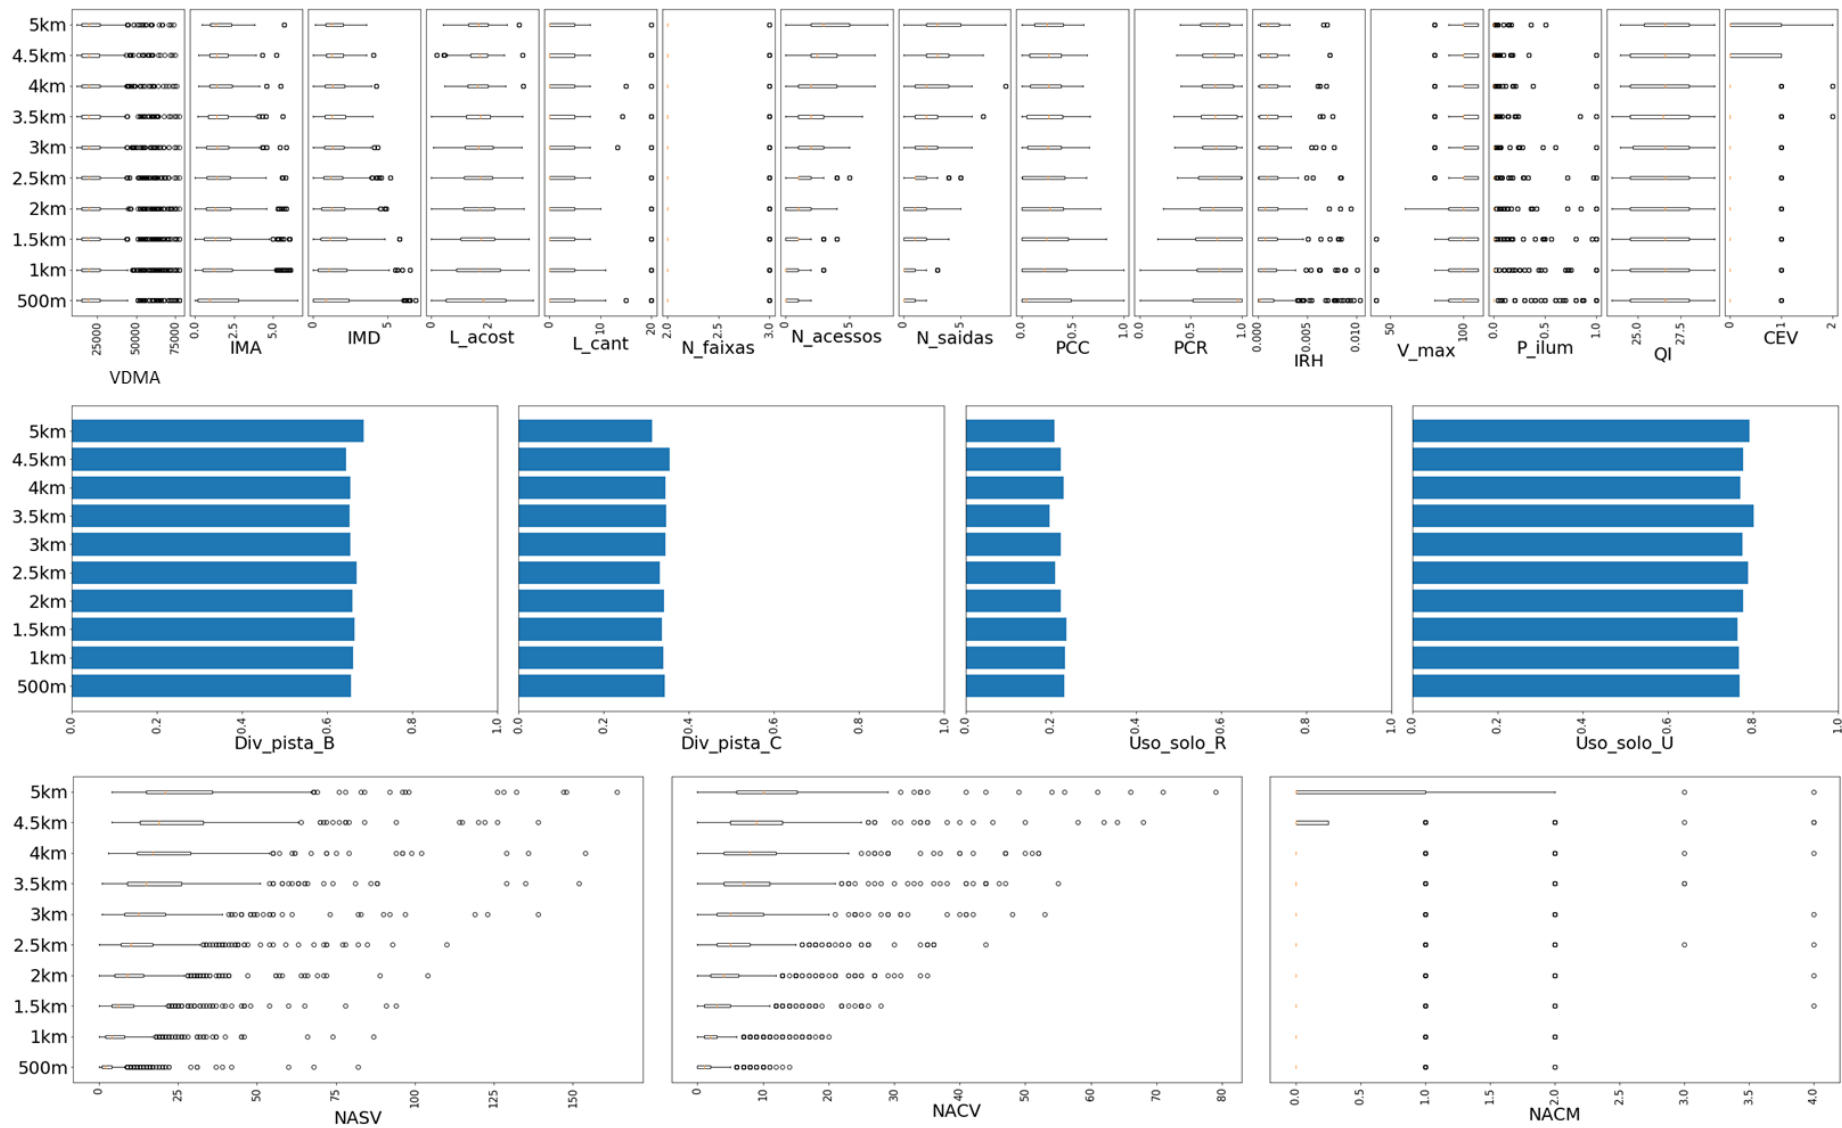
**Figura 4.6** – Distribuição das variáveis segundo cada extensão de segmento, na Pista Norte, no período 2011-2014



**Figura 4.7** – Distribuição das variáveis segundo cada extensão de segmento, na Pista Norte, no período 2015-2018



**Figura 4. 8** – Distribuição das variáveis segundo cada extensão de segmento, na Pista Sul, no período 2011-2014



**Figura 4.9** – Distribuição das variáveis segundo cada extensão de segmento, na Pista Sul, no período 2015-2018

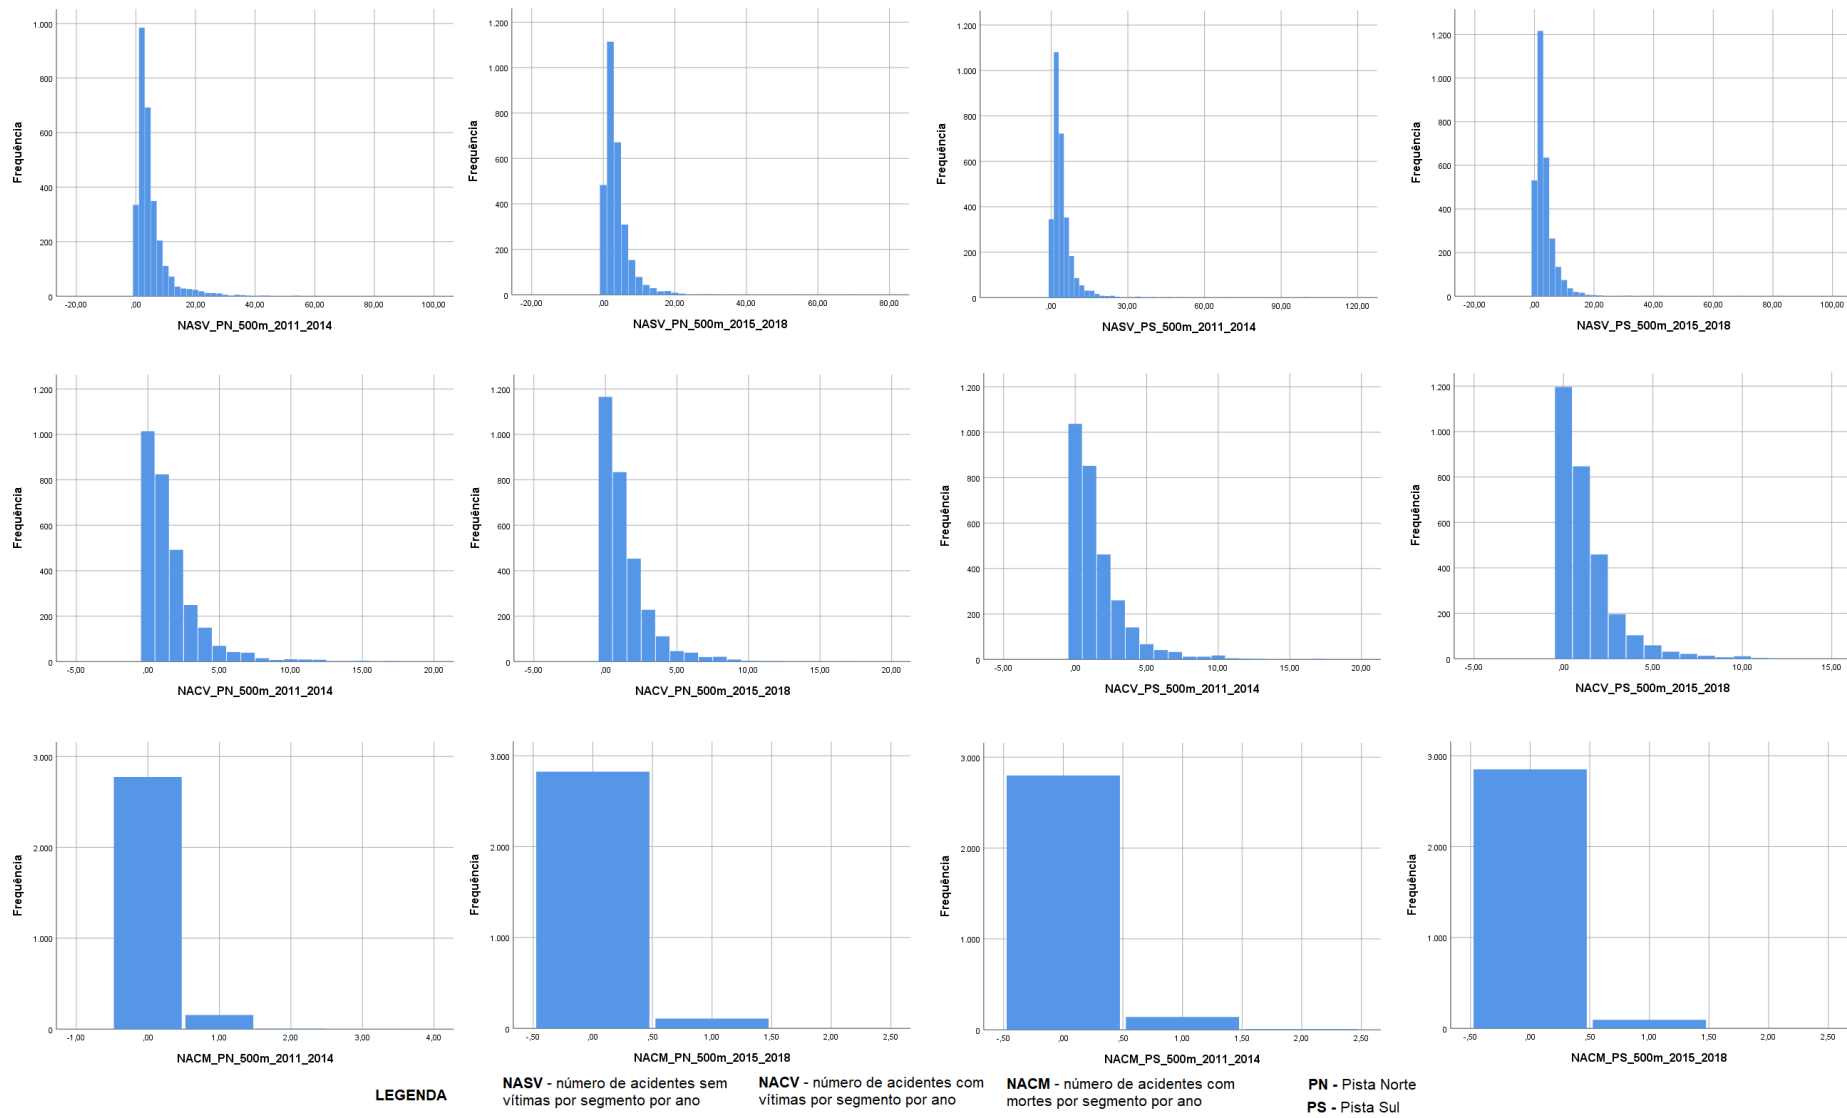
Devido à classe funcional da rodovia, foi possível observar que a segmentação em 500 m resultou em poucos segmentos com presença de acessos ou saídas, predominando ainda, no caso de ocorrência, apenas uma saída e/ou um acesso. A existência de iluminação artificial e de controladores eletrônicos de velocidade (*CEV*) se dá em menos de 5% dos segmentos, no entanto, busca-se avaliar a influência de tais dispositivos, uma vez que é presumida a existência de relacionamento deles com a ocorrência de acidentes.

Por fim, o Quociente de Irregularidade (*QI*) variável escolhida para relacionar a condição do pavimento à ocorrência de acidentes, considerando todos os registros anuais por segmento em ambas as pistas, apresenta valores entre 22,65 e 33,08, com média de 28,59 para Pista Norte e 27,89 para Pista Sul. Tal variável não possui valores discrepantes e a variação, em termos de segmentos, de pista e período, é pequena.

Na Figura 4.10 estão apresentados os histogramas dos acidentes, por tipo e período de tempo, para segmentos de 500 m. Todas as distribuições apresentam comportamento similar para correspondentes tipo de acidente e período analisado, independente da pista. Para acidentes sem vítimas, nota-se um pico junto ao 1, apontando para a alta densidade de dados em torno daquele ponto. A partir daí, tem-se sucessivos decréscimos de frequência para valores maiores de acidentes. Em média, cerca de 50% dos segmentos têm até 2 acidentes sem vítimas e 80% desses segmentos apresentam até 6 acidentes sem vítimas.

No caso de acidentes com vítimas, o pico é já no início da distribuição revelando que em torno de 40% dos segmentos não ocorreu acidentes deste tipo. Analogamente, a partir de 1 tem-se decréscimos sucessivos de frequência na distribuição, indicando a alta densidade de dados para até 2 acidentes com vítimas. Para os acidentes com mortes, como de se esperar, a concentração de dados se dá junto ao 0 (zero), uma vez que em mais de 96% dos segmentos não ocorreu acidente fatal. Nota-se, portanto, queda abrupta de 0 (zero) para 1 e similarmente, de 1 para 2, sendo que são reduzidas as observações de segmentos com 2 ou mais acidentes deste tipo.

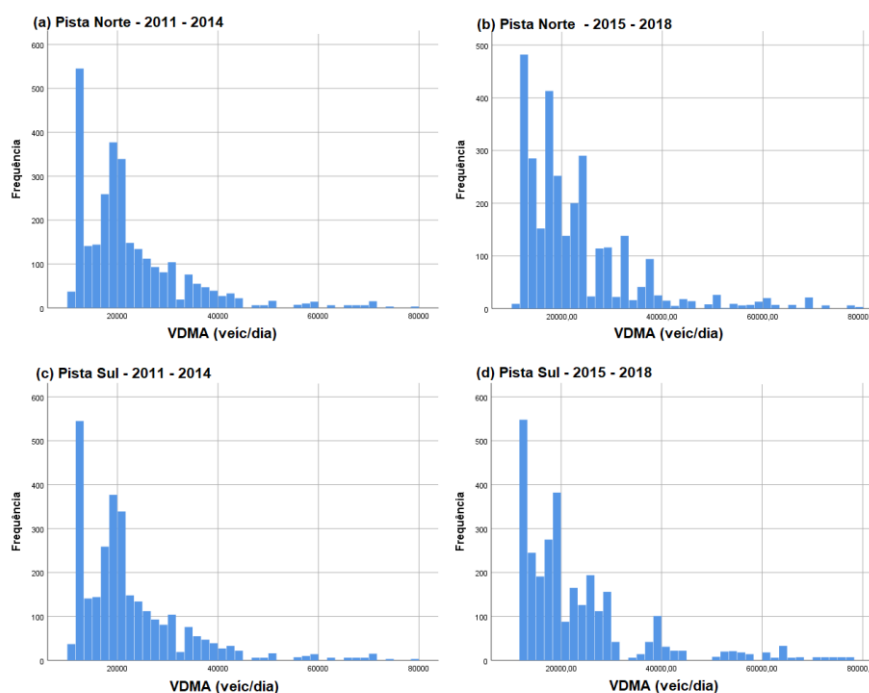
Obviamente, quanto maior a extensão do segmento, maior o valor médio de acidentes em todos níveis de severidade. Constatou-se também que o número médio de acidentes nos períodos 2011-2014 e 2015-2018 são similares, no entanto, ficam evidentes os valores inferiores para acidentes sem vítimas (*NASV*) para o segundo período.



**Figura 4.10** – Histogramas dos tipos de acidentes ocorridos por ano, em segmentos de 500 m, para diferentes pistas e períodos de tempo.

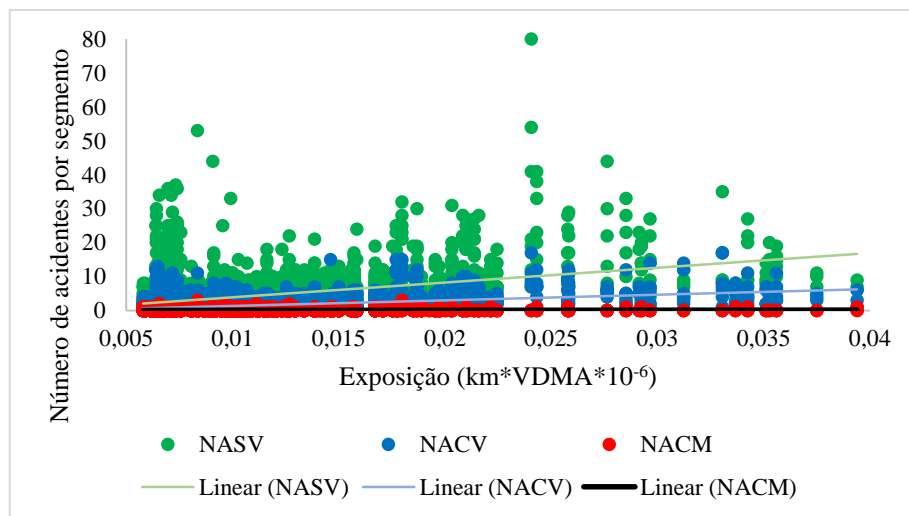
Para a Pista Norte (PN) na série histórica completa, a partir de segmentos de 3 km, todos segmentos são caracterizados pela ocorrência de, pelo menos, um acidente sem vítimas. Adicionalmente, em todos segmentos de 4 km ocorreram, no mínimo, dois acidentes; em segmentos de 4,5 km, no mínimo, três acidentes; e, em segmentos de 5 km ocorreram, no mínimo, quatro acidentes. Similar cenário foi constatado na Pista Sul (PS) apresentando, entretanto, em todos os segmentos de 4 km, no mínimo, três acidentes.

As distribuições do volume de tráfego diário médio anual (VDMA) ao longo dos segmentos de 500 m estão apresentadas na Figura 4.11. No período 2011-2014 para ambas as pistas as distribuições são assimétricas com existência de dois picos, o maior para volumes no entorno de 12.000 veíc./dia e o segundo para valores próximos à 18.000 veíc./dia. Já no período de 2015 a 2018, nota-se que nos valores mais baixos de *VDMA* as frequências são mais próximas, embora sejam notáveis os picos. ligeira diferença na distribuição, quando comparada ao período anterior. Em média, 90% dos segmentos analisados são caracterizados por tráfego inferior à 40.000 veíc./dia. Existe, no entanto, em todos os casos, acumulação junto aos níveis iniciais de *VDMA*. Para o período 2011-2014, 50% dos segmentos têm volume de tráfego inferior a 19.846 veíc./dia e de 2015 a 2018, 19.137 veíc./dia é o limite para 50% das observações. Os valores médios de *VDMA* são da ordem de 22.500 veíc./dia, em todas as agregações temporais e extensões de segmentos.

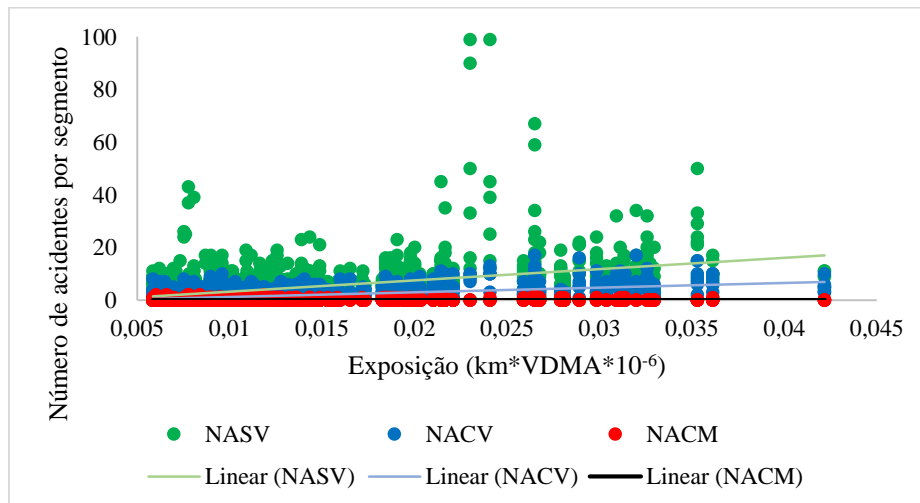


**Figura 4.11** – Histogramas do volume de tráfego em segmentos de 500 m, para diferentes pistas e períodos de tempo

Ainda nessa exploração inicial, está apresentada nas Figuras 4.12 e 4.13 a relação entre a taxa de exposição ( $km*VDMA*10^{-6}$ ) e o número de acidentes, por severidade. Percebe-se que a maior variabilidade dos dados ocorre para os acidentes sem vítimas e com vítimas, cujos coeficientes angulares das retas de tendência são mais altos. No caso dos acidentes com mortes, as retas ajustadas estão com inclinação próxima a zero. Os dados apresentados referem-se aos segmentos de 500 m da Pista Norte (PN) e Pista Sul (PS), no período de 2011 a 2014, no entanto, os demais casos para outras extensões e períodos de tempo, são similares.



**Figura 4.12**– Relação entre exposição e acidentes, segmentos de 500 m, PN, 2011-2014



**Figura 4.13** – Relação entre exposição e acidentes, segmentos de 500 m, PS, 2011-2014

A partir dessa exploração inicial dos dados, acredita-se ser possível proceder, de forma adequada, ao desenvolvimento de modelos de previsão de acidentes com o conjunto de variáveis apresentadas, forma de medição, distribuição e comportamento.



## 5. MODELAGEM E VALIDAÇÃO

Neste capítulo são apresentados os aspectos detalhados do processo de modelagem e validação.

### 5.1. MODELAGEM

Nesta seção são apontados os detalhes do emprego de redes neurais artificiais (RNA) e do modelo multivariado Poisson lognormal (MVPLN) para modelagem.

#### 5.1.1. Redes Neurais Artificiais

A regularização das variáveis e testes exploratórios com outros regressores foram conduzidos e documentados no Apêndice B. Confirmada a utilização de RNA, restou definir os parâmetros da rede e detalhes da execução dos modelos.

(i) Definição de parâmetros da rede neural

O funcionamento e aspectos mais importantes das redes neurais foram apresentados no Capítulo 2. De todo modo, é importante apresentar a definição dos parâmetros adotados neste estudo.

- *Arquitetura da rede*

Em termos de arquitetura, basicamente as RNA se dividem entre: *feedforward* e recorrentes. O primeiro caso é de redes diretas com fluxo de informação em uma única direção. O outro tipo, redes recorrentes, apresenta laços de retroalimentação, utilizando suas saídas para alimentar ciclicamente suas entradas (RUSSEL & NORVIG, 2003). As redes recorrentes são mais complexas e fazem sentido para problemas de classificação de imagem, na captura das ricas dependências contextuais em regiões de imagens (HOCHREITER *et al.*, 1997; GRAVES, 2012; SHUAI *et al.*, 2016).

Entre as redes diretas, destacam-se a *multilayer perceptron* (rede tipo *perceptron* de múltiplas camadas) e convolucionais. Esse último tipo é utilizado especialmente para questões ligadas a visão computacional: classificação de imagens, detecção de objetos, segmentação de cenas, extração de características e reconhecimento de padrões (SERMANET & LECUN, 2011;

LONG *et al.*, 2015; SIMONYAN & ZISSERMAN, 2015; BADRINARAYANAN & CIPOLLA, 2016; PENG *et al.*, 2017).

Trata-se de uma variação das redes *Multilayer Perceptron* (MLP), utilizando múltiplas camadas heterogêneas. As primeiras camadas são responsáveis por pré-processar a imagem, reconhecendo padrões (forma, textura, etc), em contrapartida as últimas camadas são de neurônios *perceptrons* e realizam a classificação do padrão de entrada (RODRIGUES, 2018).

Outro caso especial de MLP são as Redes Neurais de Função de Base Radial (RBF), as quais têm como estrutura básica apenas uma camada oculta. Cada neurônio nessa camada intermediária usa uma função de base radial não linear como função de ativação. Desta forma, essa camada executa uma transformação não linear da entrada, e a camada de saída é um combinador linear que mapeia a não linearidade para um novo espaço. Em outras palavras, nessa abordagem aprender é equivalente a encontrar uma superfície, em um espaço multidimensional, que forneça melhor ajuste para os dados de treinamento. Esse tipo de rede é mais adequado para problemas de classificação e quando se tem um número elevado de dados de entrada. Além disso, diferente da MLP, uma rede constrói aproximadores locais, o que compromete a capacidade de generalização global (HAYKIN, 2001; YU *et al.*, 2011; DASH *et al.*, 2016; MARKOPOULOS *et al.*, 2016).

Diante disso, considerando o problema em análise, foi empregada Redes Neurais Perceptron de Múltiplas Camadas (MLP), o tipo mais utilizado em redes neurais. A arquitetura típica desse tipo de rede foi apresentada no Capítulo 2.

Haykin (2009) destaca a importância de adequada definição do número de neurônios e camadas ocultas da rede. Essa definição baseia-se essencialmente na experimentação dos dados. Na análise exploratória verificou-se que a utilização de 25 neurônios conduzia a resultados estáveis e ainda, que mais de uma camada oculta na rede favorecia o ajuste dos modelos, motivo pelo qual adotou-se uma camada oculta adicional para cada nova extensão de segmento, conforme apresentado na Tabela 5.1.

A definição das configurações adotadas foi resultado de diversas experimentações, sendo bastante razoável visto que, com menos neurônios e/ou camadas ocultas o desempenho do modelo era inferior e, com mais neurônios e/ou camadas ocultas os resultados eram bastante

similares, mas, com custo computacional muito mais alto, implicando numa complexidade desnecessária ao modelo.

**Tabela 5. 1** - Número de neurônios e camadas ocultas para cada extensão de segmento

Extensão do segmento	Número de neurônios – Número camadas ocultas
500 m	25 – 1
1 km	25 – 2
1,5km	25 – 3
2 km	25 – 4
2,5 km	25 – 5
3 km	25 – 6
3,5km	25 – 7
4 km	25 – 8
4,5 km	25 – 9
5 km	25 – 10

- *Processo de treinamento da rede*

A teoria de redes em multinível treinadas com aprendizado por retropropagação (método *backpropagation*) é que evidenciou o potencial das redes neurais, que não havia se popularizado após apontamento de graves limitações do método por Minsky e Papert (1969). Conforme o entendimento de Braga *et al.* (2011), nesse algoritmo de treinamento busca-se a minimização dos erros, a partir do ajuste dos pesos da rede. Neste processo, o treinamento ocorre em duas fases: *forward* e *backward*. A primeira fase é utilizada para definição da saída para um dado padrão de entrada e envolve os seguintes passos:

1. A entrada é apresentada à primeira camada da rede,  $C^0$
2. Para cada camada  $C^i$ , a partir da camada de entrada:  
Após os nós da camada  $C^i$  ( $i > 0$ ) calcularem seus sinais de saída, estes servem como entrada para a definição das saídas produzidas pelos nós da camada  $C^{i+1}$
3. As saídas produzidas pelos nodos da última camada são comparadas às saídas desejadas.

A fase *backward*, por sua vez, utiliza a saída desejada e a saída prevista pela rede para atualizar os pesos de suas conexões a partir da última camada, até chegar à camada de entrada, sendo:

1. Os nós da camada atual têm seus pesos ajustados, com vistas à redução de erros.

2. O erro de um nó da camada oculta é calculado utilizando os erros dos nós, da camada seguinte, conectados a ele, ponderados pelos pesos das conexões entre eles.

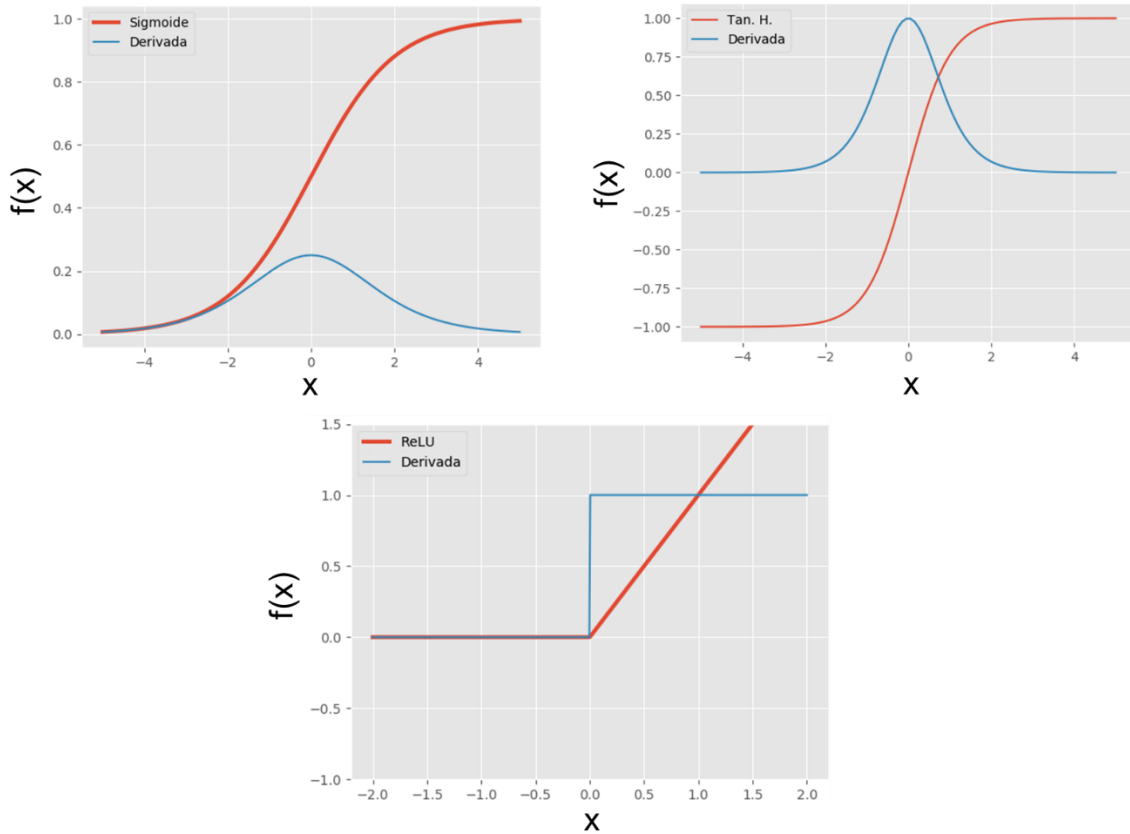
O método do gradiente descendente é bastante utilizado para fins de otimização em problemas de modelagem, inclusive o algoritmo de retropropagação, geralmente, baseia-se nele (RUSSELL & NORVIG, 2003; MICHALEWICZ & FOGEL, 2004; ROTHLAUF, 2011; SHARMA, 2014). Mais recentemente, Kingma e Ba (2015) propuseram um método de otimização melhorado, denominado *Adam* (*Adaptive moment estimation*) – estimativa de momento adaptativo, em português. Este método utiliza uma variação do gradiente estocástico para realizar a minimização da função de custo e, conseqüente, otimização do modelo.

Diferente do gradiente descendente que mantém uma taxa de aprendizado única e invariável para todos os pesos, o *Adam* utiliza taxas de aprendizado para cada parâmetro, que são adaptadas separadamente durante o treinamento (RODRIGUES, 2018). E mais, segundo Ruder (2016), a utilização desse otimizador melhora a convergência e contribui para evitar *overfitting* do modelo. As características apresentadas motivaram a utilização desse otimizador no presente trabalho.

Outro parâmetro necessário de configuração é a taxa de aprendizado. Ela está relacionada à convergência do processo de aprendizado, influenciando na velocidade de mudança nos pesos a cada nova iteração. De acordo com Kingma e Ba (2015),  $\eta = 0,001$  pode ser um valor inicial a ser adotado para problemas de aprendizado de máquina. Tal valor foi adotado e, a partir dele, verificou-se o comportamento da função de custo em termos do número de iterações. Uma taxa de aprendizado adequada não deve ser muito pequena a ponto de recair no problema de mínimo local, nem tão grande que oscile em torno do mínimo global. Mediante exploração dos dados, optou-se por uma taxa de aprendizado  $\eta = 0,0001$ , notando-se com ela estabilidade da função de custo nas primeiras iterações, seguida de diminuição suave a medida que o número de iterações aumentava. Assim, assegurou-se uma trajetória suave e pequenas mudanças nos pesos a cada nova iteração.

Em relação à função de ativação, com a crescente exploração de *Deep Learning*, a função retificadora linear (*rectified linear function*, ReLU) tem sido mais utilizada por facilitar o processo de treinamento (NAIR & HINTON, 2010; GOODFELLOW *et al.*, 2016). Conforme

Vieira *et al.* (2017), diferente das funções sigmoidais, que saturam a partir de determinado ponto, a ReLU tem processo de otimização facilitado por sua função ser parecida com a identidade, como é observado na Figura 5.1.



**Figura 5.1** - Comportamento de diferentes funções de ativação  
 Fonte: Facure (2017) adaptado

A função ReLU retorna o valor zero para entradas negativas e tem um aspecto linearmente crescente para valores maiores ou iguais a zero ( $f(x) = \max(0, x)$ ). Segundo Glorot *et al.* (2011), o melhor desempenho dessa função não linear semi-retificadora também deve-se a capacidade dela capturar propriedades que são próprias dos neurônios biológicos: i) para algumas entradas, os neurônios são completamente inativos; ii) para algumas entradas, a saída de um neurônio é proporcional à sua entrada; iii) os neurônios devem ter ativações esparsas. Tendo em conta a simplicidade da função e resultados superiores à das funções tradicionais, a ReLU foi empregada neste trabalho.

- *Estratégia de convergência para minimização de overfitting*

Mesmo diante das potencialidades das RNA, Goodfellow *et al.* (2016) afirmam que dois aspectos importantes no paradigma de aprendizado de máquina são: *underfitting* e *overfitting*. O primeiro caso ocorre quando o modelo não é capaz de obter um valor de erro suficientemente baixo no conjunto de treinamento. Em contrapartida, o *overfitting* ocorre quando a diferença entre o erro de treinamento e erro de validação é muito grande. Este parece ser o mais importante dos dois desafios. Neste caso, a rede apresenta uma capacidade superior à complexidade do problema e, portanto, sobreajusta-se ao conjunto de treinamento. Assim, após o ciclo de treinamento, ao ser apresentada a um novo conjunto de padrões (dados de teste), a rede incorre em erros muito superiores à fase do treino. Tal aspecto compromete a capacidade de generalização da rede (LAWRENCE *et al.*, 1997; BRAGA *et al.*, 2011). Note-se, entretanto que, uma diferença percentual significativa entre valores de métricas, desde que os resultados de validação sejam admissíveis (em termos de medidas de desempenho e análise de resíduos), não configuram *overfitting*.

Diversas estratégias têm sido utilizadas para minimizar essa questão, dentre elas, a mais utilizada é o *early stopping*, interrompendo-se o treinamento antecipadamente, quando o erro de validação começa a subir. Outra alternativa que vem sendo investigada por pesquisadores é a adição de ruído nos dados de entrada (*noise injection* ou *additive noise*, em inglês). Conforme Holmström e Koistinen (1992) e An (1996), o treinamento com uso de ruídos ajuda a rede na generalização com dados novos. Isso porque, segundo os autores, cada conjunto de dados de treinamento é uma amostra finita da população subjacente, o que pode não representar a população com precisão. Treinar as RNA com adição de ruído amplia o conjunto de treinamento, complementando-o com dados artificiais que sejam semelhantes, mas diferentes dos dados reais de treinamento.

Nesta abordagem, a geração sintética de dados ocorre apenas no conjunto de treinamento, preservando-se o conjunto real de dados para a validação. Emprega-se, especialmente, um ruído estatístico cuja função de densidade de probabilidade é igual a uma distribuição normal, o ruído gaussiano. Trabalhos como de Zur *et al.* (2004), Jiang *et al.* (2009), Zur *et al.* (2009), Nagabushan *et al.* (2016) e Li e Liu (2016) demonstraram os benefícios do emprego desta abordagem para minimizar o *overfitting*.

Nesta linha também tem ganhado espaço a estratégia denominada *transfer learning*, definida como a capacidade de um sistema utilizar o conhecimento aprendido em uma tarefa para resolver outro problema com características similares (PAN & YANG, 2010; GOODFELLOW *et al.*, 2016). A transferência de aprendizagem, portanto, reutiliza parcial ou totalmente os parâmetros de um modelo ajustado para acelerar o treinamento e melhorar o desempenho de um novo modelo. Na maioria dos casos, isso é feito por transferência dos pesos dos neurônios. Uma rede é inicialmente treinada e os pesos de algumas camadas são transferidos para uma segunda rede neural, que são tomados como ponto de partida.

A técnica descrita é especialmente interessante quando a quantidade disponível de dados é pequena. A transferência de aprendizagem possibilita, de forma eficaz, treinar uma rede complexa usando poucos dados de treinamento sem causar *overfitting* (HUANG *et al.*, 2017). Recentemente, diversos pesquisadores têm se dedicado à investigação e aplicação de *transfer learning* para melhoria de modelos de mineração de dados, a exemplo de Yosinski *et al.* (2014), Oquab *et al.* (2014), Azizpour *et al.* (2015), Akçay *et al.* (2016), Castrejon *et al.* (2016), Zheng *et al.* (2016), Nanni e Ghidoni (2017), Nanni *et al.* (2017) e Kaya *et al.* (2019). Em tal caso, não se tem a necessidade de geração sintética de dados e pode-se trabalhar com pequeno conjunto de dados originais. Essa abordagem, assim, otimiza a convergência do modelo e ao mesmo tempo, minimiza o sobreajuste dos dados.

Em se tratando deste estudo, foram realizados experimentos com adição de ruídos, todavia, sem resultados promissores. O desempenho dos modelos não melhorou, mas o custo computacional foi desproporcionalmente aumentado. Por este motivo optou-se pela não utilização deste método. Por outro lado, foram auferidos bons resultados com o emprego conjunto do *early stopping* e *transfer learning*.

Adotou-se o número máximo de iterações de 10.000 e como critério de parada (*early stopping*) a diferença relativa de  $1 \times 10^{-4}$  entre iterações. Esses são os valores sugeridos por Pedregosa *et al.* (2011) quando empregado o otimizador *Adam*. A interpretação da tolerância de convergência é: quando a diferença entre valores da função de custo de duas iterações sucessivas for menor ou igual a 0,0001 por 10 vezes consecutivas, admite-se que a convergência do modelo foi atingida e a execução é concluída; caso isso não ocorra, a execução é finalizada na 10.000ª iteração.

Já o *transfer learning* consistiu em reutilização do conhecimento adquirido da rede anterior na rede atual, em termos de extensão de segmento. Doutra forma, o conhecimento aprendido pela rede para modelar a previsão de acidentes em segmentos de extensão  $n$  foi reutilizado para a inicialização dos pesos da rede destinada a modelar a previsão de acidentes em segmentos com extensão  $n + 0,5$  km.

- *Resumo dos parâmetros*

Na Tabela 5.2 estão sintetizadas as informações relativas aos parâmetros empregados nas redes neurais.

**Tabela 5. 2 – Resumo dos parâmetros da rede neural**


Tipo de rede	Nº de neurônios e camadas ocultas	Processo de treinamento	Função de ativação	Taxa de aprendizado	Estratégia de convergência
<i>Multilayer perceptron</i> (MLP)	Varia de 25 neurônios e 1 camada a 25 neurônios e 10 camadas	Algoritmo <i>backpropagation</i> associado ao otimizador <i>Adam</i>	ReLU	0,0001	<i>Early stopping</i> e <i>transfer learning</i>

(ii) Execução dos modelos

Para cada um dos 40 modelos, anterior à execução das redes, procedeu-se à divisão da respectiva base de dados em dois subconjuntos: treinamento e teste (validação), em que o subconjunto do treino é utilizado para o ajuste do modelo e o subconjunto de teste para verificar a qualidade de previsões a partir de dados desconhecidos (AZEVEDO, 2018). A abordagem de validação cruzada utilizada foi a execução repetida do procedimento *holdout* (*repeated hold out* - RHO) com particionamento de 80% (treinamento) e 20% (teste) do total dos dados a cada execução (BURMAN, 1989). Neste caso, a cada nova rodada dois novos conjuntos de treinamento e validação são particionados, o que reduz a dependência dos valores à partição aleatória inicial da amostra que ocorre no método de validação *k-fold*. Shao (1993) e Zhang (1993) afirmam que esta abordagem é bastante consistente para avaliação do modelo. Neste estudo foram realizadas 30 execuções para cada modelo, de forma que, para cada nova execução dois novos subconjuntos aleatórios de treinamento e teste foram gerados (Figura 5.2). O



objetivo de repetir as execuções múltiplas vezes foi aumentar a confiabilidade quanto ao comportamento do regressor, RNA.



**Figura 5.2**– Esquema de validação holdout dos modelos

Os modelos foram executados com uso de *Scikit learn* (PEDREGOSA *et al.*, 2011), uma biblioteca de aprendizado de máquina de uso geral escrita em *Python* (PYTHON, 2019). Associadas ao *Scikit learn* estão as bibliotecas:

- *NumPy*: lida eficientemente com a matriz de entradas e saídas (*inputs* e *outputs*), possibilitando operações básica sobre ela.
- *SciPy*: executa funções matemáticas mais complexas, estando vinculada a outras bibliotecas compiladas (*BLAS*, *Arpack* e *MKL*) para garantir alto desempenho. Juntos, *NumPy* e *SciPy* fornecem um ambiente científico robusto para computação numérica e fundamentam os algoritmos empregados neste estudo.
- *Matplotlib*: é uma biblioteca de plotagem de resultados fortemente integrada a outras bibliotecas do *Python*.

Conforme destacam Schaul *et al.* (2010) e Abraham *et al.* (2014), a *Scikit learning* fornece implementações eficientes de algoritmos de ponta, acessíveis a não especialistas em aprendizado de máquina e reutilizáveis em diversas disciplinas científicas e campos de aplicação, o que motivou sua utilização neste trabalho.

### 5.1.2. Modelo multivariado Poisson lognormal (MVPLN)

À princípio, fez-se o ajuste na forma e apresentação dos conjuntos de dados de entrada para adequado reconhecimento da plataforma utilizada para simulação. Da mesma maneira, testes exploratórios foram conduzidos e apontaram para melhoria de ajuste dos modelos quando da

transformação logarítmica das variáveis de volume de tráfego (*VDMA*) e inverso do raio de curva horizontal (*IRH*), tendo sido, portanto, adotadas estas duas transformações.

A formulação do modelo multivariado Poisson lognormal (MVPLN) foi apresentada no Capítulo 2. Os coeficientes dos modelos foram estimados por meio de abordagem Bayesiana usando simulação de Monte Carlo via Cadeias de Markov (MCMC). Detalhes acerca desse tipo de simulação fogem ao escopo desse estudo, no entanto, Gelman *et al.* (2003), Congdon (2003) e Kruschke (2015) podem ser consultados para essa finalidade.

Resgatando as Equações 2.2 e 2.3, tem-se que distribuição *a priori* de  $\beta_s$  (coeficientes) é normal multivariada e a distribuição *a priori* conjugada da matriz de precisão é *Wishart*, como sugerido na literatura (PARK & LORD 2007; MA *et al.*, 2008; AGUERO-VALVERDE & JOVANIS, 2009).

Ainda conforme Ma *et al.* (2008), o foco é na correlação entre número de acidentes com diferentes severidades para um mesmo segmento, partindo do pressuposto que o número de acidentes nos segmentos da rodovia seja independente (por exemplo, não há correlação espacial). De forma complementar, Agüero-Valverde *et al.* (2016) afirma que no caso do MVPLN em que há a fixação dos efeitos aleatórios ao longo do tempo, são obtidos modelos mais parcimoniosos e com melhor ajuste, além de controlar a correlação temporal, uma vez que existe apenas um efeito aleatório por segmento.

Os coeficientes  $\beta_s$ , incluindo os interceptos, foram modelados usando *a priori* normal não informativa:

$$\beta_s = N(0, 1000) \quad (5.1)$$

Assumindo que os efeitos aleatórios de cada nível de severidade de acidente são independentes, são propostas as seguintes distribuições *a priori* para os efeitos de heterogeneidade:

$$\varepsilon_{its} \sim N(0, \tau_s^{-1}) \quad s = 1, 2, 3 \quad (5.2)$$

Em que  $\tau_s$  é o inverso da variância para cada severidade  $s$ , também chamada precisão. A precisão segue a distribuição gama *a priori* com média de 10 e variância de 10.000, da seguinte forma:

$$\tau_s = \text{gama}(0.01, 0.001) \quad s = 1, 2, 3 \quad (5.3)$$

Para o modelo multivariado, distribuições *a priori* correlacionadas no vetor de efeitos aleatórios são estimadas usando distribuição *a priori* normal multivariada (MN):

$$\varepsilon_i \sim \text{MN}(\mu_i, \Sigma) \quad (5.4)$$

Em que  $\mu_i$  é o vetor de zeros  $\mu_i = (0, 0, 0)$  e  $\Sigma$  é a matriz de variância-covariância com distribuição *a priori* nos hiperparâmetros definida por:

$$\Sigma^{-1} \sim \text{Wishart}(R, n) \quad (5.5)$$

Em que  $\Sigma^{-1}$  é a matriz positiva definida simétrica (também denominada como matriz de precisão);

$$R = \text{matriz escalar} = \begin{pmatrix} 0,1 & 0,005 & 0,005 \\ 0,005 & 0,1 & 0,005 \\ 0,005 & 0,005 & 0,1 \end{pmatrix}$$

$n$  é o número de graus de liberdade,  $n = 3$ .

Os valores de  $R$  foram recomendados por Carlin e Louis (1996) e Gelman *et al.* (2003) para produzirem uma distribuição *a priori* não informativa para a matriz de precisão, análoga a distribuição gama não informativa para *a priori* da precisão univariada apresentada na Equação 5.3.

Semelhante ao procedimento empregado com redes neurais, porém sem utilizar validação cruzada, fez-se o ajuste de modelos com uso de MVPLN. Para tanto, as simulações MCMC foram executadas na plataforma *OpenBUGS* versão 3.2.3 (LUNN *et al.*, 2009; OPENBUGS,

2019). Nessa abordagem são gerados valores de parâmetros a partir de distribuições aproximadas e que são distribuições que convergem para as distribuições *a posteriori* alvos.

As simulações foram procedidas com o descarte inicial das primeiras 1.000 iterações (*burn-in*), a fim de eliminar a influência dos valores iniciais e, em seguida, para estimativa dos parâmetros foram executadas de 21.000 a 125.000 iterações, a depender da extensão do segmento (Tabela 5.3).

A convergência foi avaliada por inspeção visual dos parâmetros das cadeias de Markov e adotou-se como critério de parada o erro de MCMC menor ou igual a 5% do desvio-padrão da estimativa ou, ainda, atendimento do limite de iterações do *software*, conforme sugerido por Tazhibi *et al.* (2013).

**Tabela 5.3** – Número de iterações da simulação de MCMC para cada extensão de segmento

Extensão do segmento	Número de iterações
500 m	21.000
1 km	44.000
1,5km	65.000
2 km	89.000
2,5 km	100.000
3 km	100.000
3,5km	125.000
4 km	125.000
4,5 km	125.000
5 km	125.000

Após convergência, os coeficientes foram reportados em termos da média e desvio padrão da amostra e também do percentil 2,5 e percentil 97,5. A partir das simulações também foi possível obter os valores previstos para cada observação, útil para avaliação do desempenho do modelo.

## 5.2. VALIDAÇÃO

Embora na literatura não haja consenso sobre uma definição precisa (CRONBACH, 1971; PEDHAZUR & SCHMELKIN, 1991), a validação visa averiguar a adequabilidade de um modelo ao propósito para o qual foi desenvolvido, fornecendo segurança em sua utilização e interpretação de resultados.

Para modelagem de redes neurais, a validação consiste geralmente na avaliação do desempenho preditivo do modelo em um conjunto de validação independente (amostra de 20% do conjunto total de dados). Isso, no entanto, ignora outros aspectos de validação do modelo considerados boas práticas na modelagem de acidentes de trânsito, como análise de resíduos (validade replicativa) e verificação da plausibilidade do modelo em relação ao entendimento prévio do fenômeno (validação estrutural). Diante disso, Humphrey *et al.* (2017), valendo-se das considerações de Gass (1983) quanto aos aspectos norteadores do processo de validação, propuseram uma estrutura de validação para RNA, de forma a abranger os aspectos de validade do modelo acima mencionados.

As redes neurais trabalham com a premissa de que existe uma função real subjacente a um sistema capaz de relacionar um conjunto de variáveis preditoras independentes a uma ou mais variáveis dependentes. Assim, se  $y$  é a variável resposta e  $x$  é um vetor das variáveis de entrada, assume-se que:

$$y = f(x, \theta) + \varepsilon \quad (5.6)$$

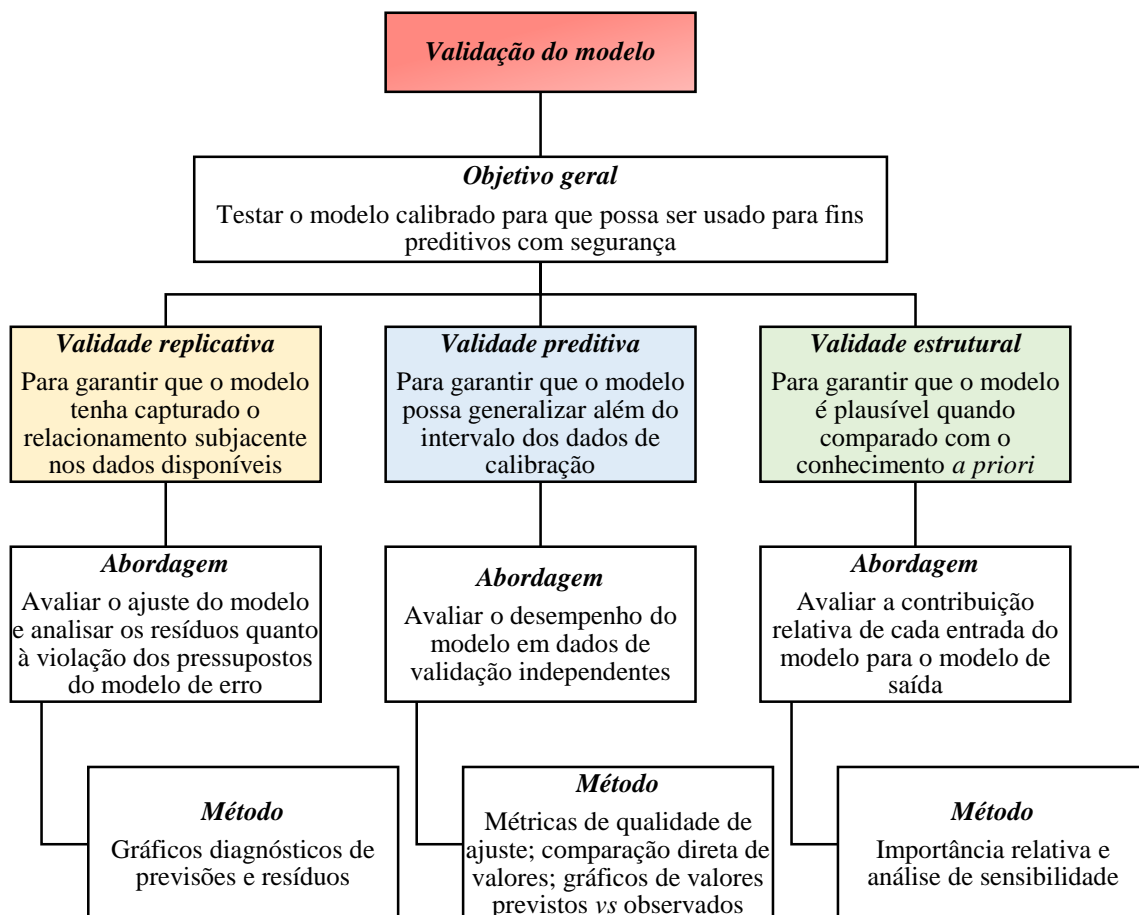
Em que  $f(\cdot)$  é a função do modelo,  $\theta$  é um vetor dos parâmetros do modelo (pesos das conexões, por exemplo) e  $\varepsilon$  é um erro aleatório ou perturbação que responde pela incerteza natural inerente ao processo, juntamente com quaisquer erros de medição associados a  $y$ . O objetivo da calibração da rede, ou treinamento, é encontrar estimativas dos parâmetros  $\hat{\theta}$  do modelo, de modo que o componente determinístico de  $y$  ( $f(x, \theta)$ ) é apropriadamente capturado.

Como a calibração das redes neurais é tipicamente baseada no Método dos Mínimos Quadrados (MMQ), em que os parâmetros são estimados de forma a minimizar a soma dos quadrados dos resíduos (*Sum Square Error* – SSE), ou critério relacionado, entre os dados observados e os resíduos, pode-se assumir como válidas algumas suposições acerca da distribuição estatística de  $\varepsilon$ , especialmente a ausência de correlação entre os resíduos ( $\varepsilon_i$ ) e distribuição consistente com a distribuição Gaussiana. Note-se que, a distribuição normal dos resíduos não é parâmetro para considerar o modelo válido, mas condição necessária para que sejam feitas inferências acerca dos parâmetros do modelo.

Na Figura 5.3 está apresentado o protocolo de validação proposto por Humphrey *et al.* (2017), introduzindo uma estrutura abrangente que inclui três tipos de validade (replicativa, preditiva e

estrutural). A utilização de protocolos de validação é bastante proveitosa, uma vez que facilita a comparação mais objetiva do modelo e permite a identificação mais clara de suas limitações e condições de aprimoramento para desenvolvimento de modelos superiores (BIONDI *et al.*, 2012). Além disso, a execução do protocolo concede mais segurança quanto às constatações do potencial e das limitações de uso das redes neurais.

Importante deixar assente que, embora tenha sido desenvolvido com foco nas redes neurais, o protocolo de validação, especialmente as etapas de validação replicativa e preditiva, é aplicável a qualquer outro modelo de regressão. Isso motivou, inclusive, a adoção e aplicação do protocolo também para os modelos MVPLN. Para esse propósito foram utilizados o *validann package* do R (R DEVELOPMENT TEAM, 2019) e biblioteca *SALib* do Python (PYTHON, 2019).



**Figura 5.3** – Protocolo de validação de modelos RNA  
Fonte: Humphrey *et al.* (2017)

### **5.2.1. Validação Replicativa**

Um modelo é replicativamente válido se tiver capturado adequadamente o relacionamento subjacente nos dados utilizados para calibração do modelo (treinamento). Para verificação da validade replicativa, recomenda-se que os componentes determinístico e estocástico da Equação 5.6, que são similares em um modelo de regressão, sejam analisados. Métricas e gráficos são utilizados para avaliar se o modelo fornece bom ajuste para os dados de treinamento e se existe alguma estrutura não aleatória nos resíduos do modelo.

Mais a frente, no Quadro 5.1 estão assinaladas quais medidas de desempenho e análises gráficas foram conduzidas para a verificação da validade replicativa dos modelos. Dentre os modelos avaliados como válidos replicativamente, foram selecionados os quatro melhores, um por pista e período de tempo (PN\_2011\_2014, PN\_2015\_2018, PS\_2011\_2014 e PS\_2015\_2018).

### **5.2.2. Validação Preditiva**

Segundo Chapra (1997), o modelo de RNA (ou de regressão) ter passado nos testes de validade replicativa pode garantir apenas que ele fornece um bom ajuste para um único conjunto de dados – os dados de calibração. O bom desempenho do modelo sobre o conjunto de dados de calibração não assegura, entretanto, o correto comportamento preditivo do modelo (POWER, 1993).

O objetivo da validação preditiva é, portanto, verificar se o modelo pode generalizar além do intervalo de dados fornecido no treinamento. Para tanto, o desempenho preditivo do modelo é verificado em um conjunto de dados independente (conjunto de teste ou validação) que não foi até então utilizado no processo de modelagem (MAIER *et al.*, 2010).

O procedimento geral é similar ao realizado na validade replicativa, empregando-se métricas de desempenho e análise de resíduos para verificação da adequação dos modelos, consoante sugerido por Humphrey *et al.* (2017). Adicionalmente, foi feita a comparação geral da performance de validação com a de treinamento. Destaca-se que para efeitos de validação preditiva foram abordados somente os quatro melhores modelos selecionados na etapa anterior.

Essa validação não foi possível de ser conduzida para os modelos MVPLN. Nesse tipo de modelo, o termo de efeitos latentes acomoda a heterogeneidade não observada individual de cada nível de severidade, capturada pelos efeitos aleatórios. Isso permite modelar a correlação existente entre os níveis de severidade e ajuste razoável do modelo (validação replicativa), entretanto, impossibilita a utilização direta dos coeficientes estimados do modelo para previsão de acidentes em outra base de dados, no caso a base de validação. Assim, caso a forma funcional do modelo contivesse apenas os coeficientes de cada variável, ou seja, sem a variável latente, o modelo seria passível de validação preditiva utilizando, inclusive, a validação cruzada.

### 5.2.3. Métodos Empregados para Validação Replicativa e Preditiva

Considerando o proposto por Humphrey *et al.* (2017) e, de forma complementar, o que é comumente empregado na modelagem de acidentes de trânsito, as medidas e gráficos analisados para fins de verificação de validade dos modelos estão apresentados no Quadro 5.1, consoante o tipo de validação: replicativa ou preditiva. A descrição das medidas de desempenho e análises gráficas estão apresentados nos Quadros 5.2 e 5.3, respectivamente.

**Quadro 5.1** - Medidas de desempenho e análises gráficas empregadas para validação replicativa e preditiva

Medida de desempenho	Tipo de validação	Análise gráfica	Tipo de validação
M.1 - Erro relativo (ER)	VR; VP	G.1 - <i>Q-Q Plot</i>	VR; VP
M.2 - Erro logarítmico quadrático médio (MSLE)	VR; VP	G.2 - <i>Residual Q-Q Plot</i>	VR; VP
M.3 - Erro mediano absoluto percentual (MdAPE)	VR; VP	G.3 - <i>Residual Autocorrelation Function (ACF) Plot</i>	VR; VP
M.4 - Coeficiente de determinação (R <sup>2</sup> )	VR; VP	G.4 - <i>CURE Plot</i>	VR
M.5 - Estatísticas resumidas	VP	G.5 - Gráfico de linhas de valores observados e previstos	VP
<b>Nota:</b> VR é validação replicativa; VP é validação preditiva.			



**Quadro 5.2 – Métricas utilizadas para validação replicativa e preditiva dos modelos**

Medidas de desempenho		
Métrica	Fórmula	Descrição
M.1 - Erro relativo (ER)	$ER = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$	Métrica da relação entre o desvio não explicado e o desvio total. Trata-se de um índice relativo em que, quanto menor o erro, menor é a parcela de variação não explicada em termos da variação total. Quanto mais próximo de zero, mais aceitável é o modelo. Valor igual a um (ER = 1) significa que o modelo desempenha tão bem quanto a simples média dos valores observados e, ER > 1 implica que a média observada é melhor preditor que o modelo.
M.2 - Erro logarítmico quadrático médio (MSLE)	$MSLE = \frac{1}{n} \sum_{i=1}^n (\ln y_i - \ln \hat{y}_i)^2$	Este índice primeiro determina o logaritmo dos valores reais e previstos, para depois operar o MSE. O objetivo dessa métrica também é penalizar mais os erros maiores, mas não com tanta severidade.
M.3 - Erro mediano absoluto percentual (MdAPE)	$p_i = \left  \frac{y_i - \hat{y}_i}{y_i} \right $ $MdAPE = \text{mediana}(p_1, p_2, \dots, p_n)$	Trata-se do valor mediano de todos os erros absolutos percentuais entre a previsão e os dados observados. Expressa precisão como uma porcentagem do erro. É similar ao MAPE (erro médio absoluto percentual), mas com a vantagem de ser menos sensível aos efeitos de <i>outliers</i> . Não é recomendado para dados com excessos de valores zero (ou próximo a isso).
M.4 - Coeficiente de determinação (R <sup>2</sup> )	$R^2 = \left( \frac{\sum_{i=1}^n (y_i - \bar{y}_i) \times (\hat{y}_i - \bar{y}_i)}{\sqrt{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \times \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2}} \right)^2$	O coeficiente de determinação (R <sup>2</sup> ) foi empregado entre os dados observados e previstos para avaliar a correlação existente entre eles. Uma correlação perfeita (R <sup>2</sup> = 1) indica que os dados previstos foram idênticos aos previstos, logo, quanto mais próximo de 1, melhor o ajuste do modelo. Fonte da fórmula: Freitas <i>et al.</i> (2018).
M.5 - Estatísticas resumidas	$\text{Mín}_{obs} = \text{mín}(y_1, y_2, \dots, y_n)$ $\text{Máx}_{obs} = \text{máx}(y_1, y_2, \dots, y_n)$ $\bar{y}_i = \frac{\sum_{i=1}^n y_i}{n}$ $DP = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{n-1}}$	A comparação entre estatísticas resumidas (mínimo, máximo, média e desvio padrão) dos conjuntos de dados observados e previstos auxilia na verificação da convergência dos resultados, em que as características são comparadas como um todo e não ponto a ponto (Benett <i>et al.</i> , 2013). Idealmente as estatísticas calculadas para as previsões devem ter um valor próximo do valor calculado com base nas observações. Obs.: As fórmulas apresentadas são aplicáveis aos valores observados, para obtenção dessas estatísticas para os valores previstos substituir $y_1, y_2, y_n, \bar{y}_i, \bar{y}_i$ por, respectivamente, $\hat{y}_1, \hat{y}_2, \hat{y}_n, \hat{y}_i, \hat{y}_i$ .
Em que: $y_i$ é o valor observado, $\hat{y}_i$ é o valor previsto, $\bar{y}_i$ é a média dos valores observados, $\bar{\hat{y}}_i$ é a média dos valores previstos, e $n$ é o número de casos.		

**Quadro 5.3 – Elementos gráficos utilizados para validação replicativa e preditiva dos modelos**

<b>Análise gráfica</b>	
<b>Gráfico</b>	<b>Descrição</b>
G.1 - <i>Q-Q Plot</i>	Gráfico quantil-quantil dos dados observados <i>versus</i> previstos - Para construir um gráfico Q-Q das previsões do modelo em relação às observações, esses conjuntos de dados são classificados separadamente, o que remove o emparelhamento entre eles e as previsões ordenadas são plotadas em relação às observações ordenadas. Se os dados ajustados e observados forem distribuídos de maneira semelhante, os pontos devem estar aproximadamente ao longo da linha 1:1, não sendo desejável haver dispersão sobre essa linha, pois os quantis são plotados em vez de pontos de dados emparelhados. A análise gráfica permite classificar o modelo como contendo pequenos, médios ou grandes desvios (CHANG E HANNA, 2004).
G.2 - <i>Residual Q-Q Plot</i>	Gráfico quantil-quantil dos resíduos – Também conhecido como gráfico de probabilidade normal, ele pode ser usado para verificar se os resíduos são consistentes com uma distribuição gaussiana (isto é, se a suposição de normalidade é razoável). Esse gráfico é construído plotando valores ordenados dos resíduos padronizados em relação aos valores teóricos correspondentes da distribuição normal padrão. Se os resíduos forem normalmente distribuídos, eles estarão ao longo ou perto de uma linha reta. O desvio significativo desta reta indica que os resíduos provavelmente não são consistentes com a distribuição gaussiana, podendo remeter como é essa discrepância: desvios significativos no final da linha podem indicar a presença de valores extremos, enquanto a curvatura pode indicar assimetria ou cauda longa (HEIBERGER & HOLLAND, 2004).
G.3 - <i>Residual Autocorrelation Function (ACF) Plot</i>	Gráfico de autocorrelação de resíduos - Se os dados são uma série temporal, os gráficos ACF e PACF podem revelar facilmente se existe alguma autocorrelação nos resíduos – esses padrões podem não ser tão fáceis de detectar com um gráfico de séries temporais dos resíduos. (BOX <i>et al.</i> , 2015). A correlação é considerada nula se os valores de ACF (função de autocorrelação) estiverem dentro das faixas de confiança de 95% em torno de zero, dadas por $\pm 1,96 / \sqrt{N}$ . Valores significativamente diferentes de zero e padrão não aleatório indicam que os resíduos são seriamente correlacionados.
G.4 - <i>CURE Plot</i>	<p>CURE (<i>CUmulative REsiduals</i>) é um método proposto por Hauer e Bamfo (1997) baseado na análise de resíduos (diferença entre os valores observados e os previstos) acumulados em que é analisada a variação da linha para distinguir o que é um padrão que represente um bom ajuste do modelo e o que é um padrão de enviesamento sistemático do modelo. O procedimento se inicia com a ordenação crescente da variável de interesse (valores ajustados de <i>NASV</i>, <i>NACV</i> e <i>NACM</i>, neste caso, conforme apontado por Hauer (2015) para modelos com múltiplas variáveis explicativas) e conseqüente ordenação dos <math>N</math> (1, 2, ..., j, ..., N) resíduos. O resíduo acumulado para cada <math>j</math> é calculado como a soma dos resíduos de 1 a <math>j</math>. O comportamento desejável do gráfico é que os resíduos acumulados oscilem em torno de zero e raramente extrapolem as curvas de limites aceitáveis para os resíduos acumulados. Tais curvas são obtidas da seguinte forma: i) ordena-se os resíduos na ordem crescente da variável de interesse, <math>\hat{y}_i</math>, numerando-os consecutivamente 1, 2, ..., j, ..., N; ii) calcula-se o quadrado dos resíduos ordenados; iii) calcula-se <math>\hat{\sigma}^2(j)</math>, como a soma destes resíduos quadrados de 1 a <math>j</math>; iv) calcula-se <math>\sigma'(j) = \hat{\sigma}(j) \sqrt{1 - \frac{\hat{\sigma}^2(j)}{\hat{\sigma}^2(N)}}</math>; iv) acrescenta-se os limites <math>\pm 2\sigma'(j)</math> ao <i>CURE Plot</i>.</p>
G.5 - Gráfico de linhas de valores observados e previstos	Comparação direta de valores observados e previstos – Trata-se de uma estratégia útil para identificar rapidamente como as previsões podem diferir das observações, o que não é muito óbvio de claro pelas estatísticas resumidas. O comportamento ideal é de concordância pontual (entre valor observado e previsto) e de tendência geral dos dados.

#### 5.2.4. Validação Estrutural

Segundo Sudheer (2005), como os dados utilizados para o desenvolvimento de redes neurais contêm informações importantes sobre o processo físico que está sendo modelado, implicitamente se espera que um modelo treinado e validado represente o fenômeno físico do sistema.

Humphrey *et al.* (2017) alertam, entretanto, que não é garantido que os modelos de RNA que têm validade replicativa e preditiva resultem em modelos que representam relacionamentos físicos plausíveis. No caso das redes neurais isso pode ser mais comum devido a problemas com a equifinalidade em que, diferentes combinações de parâmetros do modelo (os pesos das conexões, por exemplo) resultam em desempenho preditivo semelhante (BEVEN & FREER, 2001). Consequentemente, o objetivo da validação estrutural é garantir que o comportamento do modelo seja plausível quando comparado com o conhecimento prévio do sistema que está sendo modelado.

A análise de sensibilidade se coloca como uma alternativa viável neste contexto. A sensibilidade de uma variável de entrada descreve o quanto as saídas do modelo são afetadas por variações desse *input*, ou seja, quanto mais "sensível" à variável de entrada  $x_i$ , maior sua influência na saída do modelo.

Para os modelos de RNA quatro métodos foram adotados para a verificação da validação estrutural: método de Sobol', método de Morris, perfil de sensibilidade e fator de importância das variáveis. Os dois primeiros métodos foram executados mediante uso do *SALib*, biblioteca de métodos de análise de sensibilidade disponível para o *Python*; o terceiro método foi executado com o *validann package* para o *software R*; e o último, com *Scikit learn* no *Python*.

##### (i) Índice de Sobol'

Para entender como a variação de saída pode ser atribuída a variáveis de entrada individuais e a interação entre cada uma das variáveis de entrada, os índices de sensibilidade de ordem total, primeira ordem, segunda ordem e ordem superior são calculados para refletir com precisão a influência da entrada individual e a interação entre eles, e é a isso que o índice de sensibilidade de Sobol' (1993) se propõe.

Em se tratando de modelos não lineares, a decomposição da variância da saída pode ser utilizada para análise de sensibilidade. O método de Sobol' é baseado nessa decomposição, em contribuições de efeitos individuais do parâmetro, efeitos dos pares combinados de parâmetros e assim por diante (ZHANG *et al.*, 2015), conforme equação seguinte:

$$V(Y) = \sum_i V_i + \sum_i \sum_{j>1} V_{ij} + \dots + V_{12\dots k} \quad (5.7)$$

Em que  $V(Y)$  representa a variância total da métrica do output  $Y$ ;  $V_i$  é a contribuição da variância de primeira ordem do  $i$ -ésimo parâmetro,  $V_{ij}$  é a contribuição da variância de segunda ordem da interação entre os parâmetros  $i$  e  $j$ ;  $V_{12\dots k}$  é a variância de  $k$ -ésima ordem entre todas as variáveis. É possível relacionar a variância parcial ao índice de sensibilidade de primeira ordem de Sobol' da seguinte forma:

$$S_{1i} = \frac{V_{X_i}(E_{X_{\sim i}}(Y|X_i))}{V(Y)} \quad (5.8)$$

Em que  $V_{X_i}(E_{X_{\sim i}}(Y|X_i))$  é a variância de primeira ordem de um fator  $X_i$  para a saída do modelo.  $X_i$  é o  $i$ -ésimo fator e  $X_{\sim i}$  denota a matriz de todos os fatores, exceto  $X_i$ . E o termo  $E_{X_{\sim i}}(Y|X_i)$  denota o valor esperado o output  $Y$  quando o parâmetro  $X_i$  se mantém fixo. De maneira análoga, o índice de sensibilidade de segunda ordem de Sobol' é dado pela equação:

$$S_{2ij} = \frac{V_{X_{ij}}(E_{X_{\sim i}}(Y|X_i, X_j))}{V(Y)} \quad (5.9)$$

Em que  $V_{X_{ij}}(E_{X_{\sim i}}(Y|X_i, X_j))$  é a variância de segunda ordem da interação entre os fatores  $X_i$  e  $X_j$ . Deste modo,  $S_{2ij}$  mede a quantidade de variância da resposta explicada pela interação entre os fatores  $X_i$  e  $X_j$ , e assim por diante para as todas as combinações de pares possíveis.

Também o índice de sensibilidade total de Sobol' é comumente utilizado, sendo expresso por:

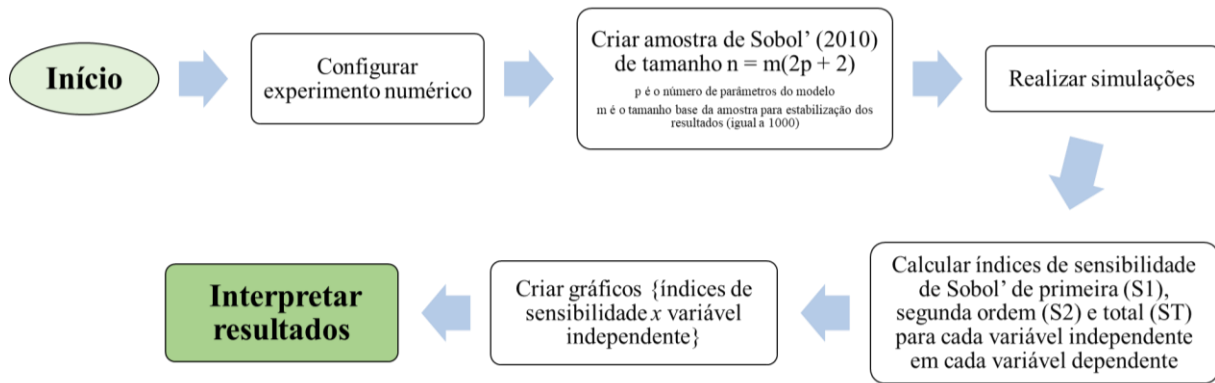
$$S_{Ti} = \frac{E_{X_{\sim i}}(V_{X_i}(Y|X_{\sim i}))}{V(Y)} = 1 - \frac{V_{X_{\sim i}}(E_{X_i}(Y|X_{\sim i}))}{V(Y)} \quad (5.10)$$

Em que  $S_{Ti}$  mede o efeito total, ou seja, de primeira ordem e ordens superiores (interações), do fator  $X_i$ .  $E_{X_{\sim i}}(V_{X_i}(Y|X_{\sim i}))$  é chamado de resíduo, em que  $X_{\sim i}$  representa todos os parâmetros incertos, menos  $X_i$ . Uma forma de se visualizar é considerando que  $V_{X_{\sim i}}(E_{X_i}(Y|X_{\sim i}))$  é o efeito de primeira ordem de  $X_{\sim i}$ , de modo que  $V(Y)$  menos  $V_{X_{\sim i}}(E_{X_i}(Y|X_{\sim i}))$  deve fornecer a contribuição de todos os termos da decomposição de variâncias que incluem  $X_i$ .

Doutro modo, a interpretação em termos de redução esperada da variância pode ocorrer da maneira descrita a seguir, motivo que Jansen (1999) chama  $V_{X_i}(E_{X_{\sim i}}(Y|X_i))$  e  $E_{X_{\sim i}}(V_{X_i}(Y|X_{\sim i}))$  de variâncias marginais superior e inferior, respectivamente.

- $V_{X_i}(E_{X_{\sim i}}(Y|X_i))$  é a redução esperada na variância que seria obtida se  $X_i$  se mantivesse fixo;
- $E_{X_{\sim i}}(V_{X_i}(Y|X_{\sim i}))$  é variância esperada que seria obtida caso todos os fatores, exceto  $X_i$ , pudessem ser fixados. Isso ocorre porque  $V_{X_{\sim i}}(E_{X_i}(Y|X_{\sim i}))$  é a redução esperada que seria obtida se todos os fatores, exceto  $X_i$ , permanecessem fixos.

Os índices de sensibilidade de Sobol' foram calculados de acordo com os métodos propostos por Sobol' (2001), Saltelli (2002) e Saltelli *et al.* (2010), nos quais os índices de sensibilidade são aproximados usando integração numérica em uma estrutura de Monte Carlo. O esquema geral de funcionamento do método está apresentado na Figura 5.4.



**Figura 5.4** – Procedimento do Método do Sobol'

Fonte: Silva (2016) adaptado

## (ii) Método de Morris

O método de Morris (1991), também chamado método de Efeitos Elementares, obtém medidas de sensibilidade global a partir de um conjunto de derivadas locais, os efeitos elementares, amostrado em um intervalo em todo o espaço de parâmetros.

Baseia-se no método *one-at-a-time* (OAT), em que o parâmetro de cada variável  $x_i$  é perturbado ao longo de um intervalo de tamanho  $\Delta_i$  para criar uma trajetória pelo espaço de parâmetros  $\Omega$ . Para um determinado modelo com  $p$  parâmetros, uma trajetória conterá uma sequência de  $p$  perturbações. Cada trajetória produz uma estimativa de efeito elementar para cada parâmetro, isto é, a proporção da variação da saída do modelo em termos da mudança no parâmetro. A Eq. 5.11 mostra a forma de cálculo do efeito elementar individual para o  $i$ -ésimo parâmetro.

$$EE_i = \frac{f(x_1, \dots, x_i + \Delta_i, \dots, x_p) - f(x)}{\Delta_i} \quad (5.11)$$

Em que as variáveis independentes são denotadas por  $x_i$  com  $i$  variando de  $\{1, 2, \dots, p\}$  e  $f(x)$  como o ponto inicial da trajetória. Usando a trajetória individual apresentada na Eq. 5.11, é possível calcular os efeitos elementares de cada parâmetro com  $p+1$  avaliações. No entanto, utilizando apenas uma trajetória, o método fica altamente dependente da localização do ponto inicial  $x$  no espaço de parâmetros  $\Omega$  e não leva em consideração as interações entre os parâmetros. E é por isso que, o método é executado sobre  $N$  trajetórias pelo espaço  $\Omega$ .

O método originalmente proposto por Morris (1991) tem como medidas de sensibilidade a média dos efeitos elementares da  $i$ -ésima variável e o seu desvio padrão, denotados por  $\mu_i$  e  $\sigma_i$ . Campolongo *et al.* (2007) aperfeiçoaram o método proposto por Morris (1991) e desenvolveram o índice  $\mu_i^*$ , calculado como a média dos valores absolutos dos efeitos elementares de uma variável  $i$  na distribuição de  $N$  trajetórias. As equações de  $\mu_i^*$  e  $\sigma_i$  estão apresentadas a seguir.

$$\mu_i^* = \frac{1}{N} \sum_{j=1}^N |EE_i^j| \quad (5.12)$$

$$\sigma_i = \sqrt{\frac{\sum_{j=1}^N [EE_i^j - \mu_i]^2}{N-1}} \quad (5.13)$$

Em que:

$N$  é o número de trajetórias da amostra;

$EE_i^j$  é o efeito elementar da  $i$ -ésima variável na  $j$ -ésima trajetória;

$j$  é cada trajetória no espaço amostral de cada variável;

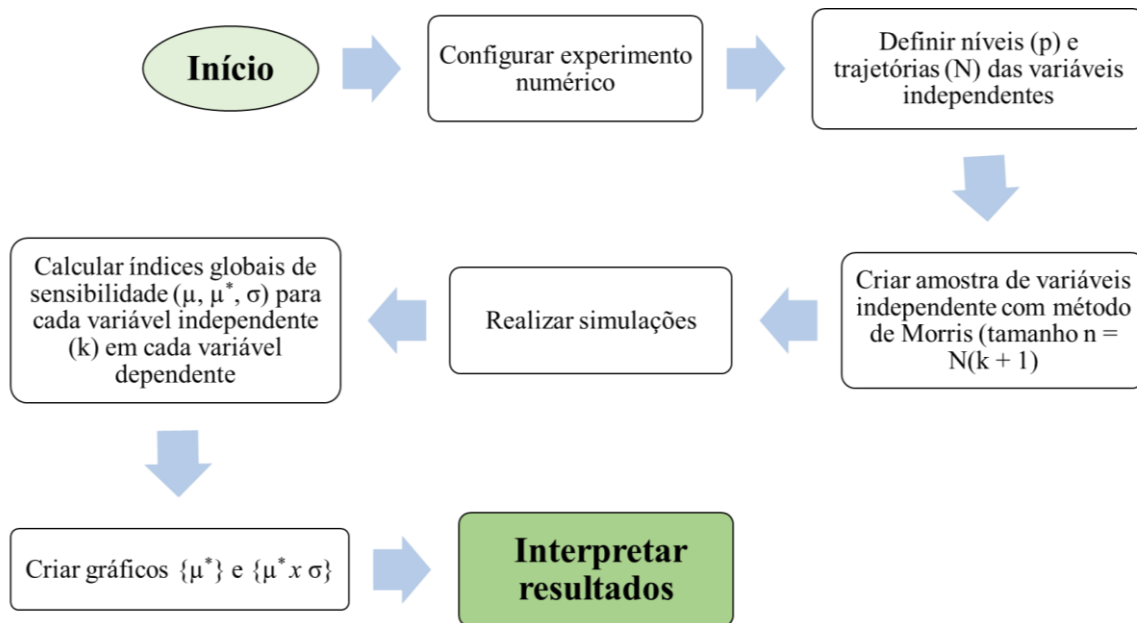
$i$  é cada variável;

$\mu_i$  é a média dos efeitos elementares da variável  $i$ ;

$\mu_i^*$  é a média em valor absoluto dos efeitos elementares da variável  $i$ ;

$\sigma_i$  é o desvio padrão dos efeitos elementares da variável  $i$ .

O processo de amostragem foi conduzido de acordo com a proposta de Campolongo *et al.* (2007), em que o número de trajetórias ( $N$ ) é definido de forma a maximizar a soma das distâncias geométricas entre todos os pares correspondentes entre duas trajetórias fixadas. Esse processo de otimização garante que uma boa varredura do espaço das entradas seja feita, minimizando as chances de os resultados serem altamente dependentes dos pontos iniciais das trajetórias. O procedimento geral do método de Morris está apresentado na Figura 5.5.



**Figura 5.5** – Procedimento do Método de Morris

Fonte: Silva (2016) adaptado

O método de Morris permite classificar as variáveis de entrada em três grupos: variáveis pouco influentes ou com efeitos insignificantes, variáveis com grandes efeitos lineares e variáveis com efeitos não lineares e/ou de segunda ordem. Valores altos de  $\mu^*$  indicam alta influência do parâmetro na saída, ao passo que altos desvios padrão ( $\sigma$ ) significam elevado comportamento não linear da variável.

Corroborando com o entendimento de Brembilla *et al.* (2018), a relação entre esses dois parâmetros também tem utilidade de interpretação. Num gráfico, os parâmetros (*inputs*) que estão abaixo da linha  $\sigma / \mu^* = 0,1$  podem ser considerados como relação quase linear com os resultados; se eles estiverem abaixo das linhas  $\sigma / \mu^* = 0,5$  e  $\sigma / \mu^* = 1$  possuem, respectivamente, comportamento monotônico e quase monotônico; por fim, acima da linha  $\sigma / \mu^* = 1$  os parâmetros apresentam alta relação não linear com os resultados e fortes indícios de interação com outros fatores de entrada.

Em relação ao comportamento monotônico das variáveis, entende-se monotonia quando, em média, um aumento no valor de uma variável de entrada induz ao aumento da variável resposta (nesse caso, monotonia positiva) ou, em contraposição, uma diminuição no valor da variável de entrada induz a uma diminuição do valor da saída (monotonia negativa). E ainda, é possível ocorrer monotonia ambígua, o que significa que, dependendo do valor da entrada, às vezes um



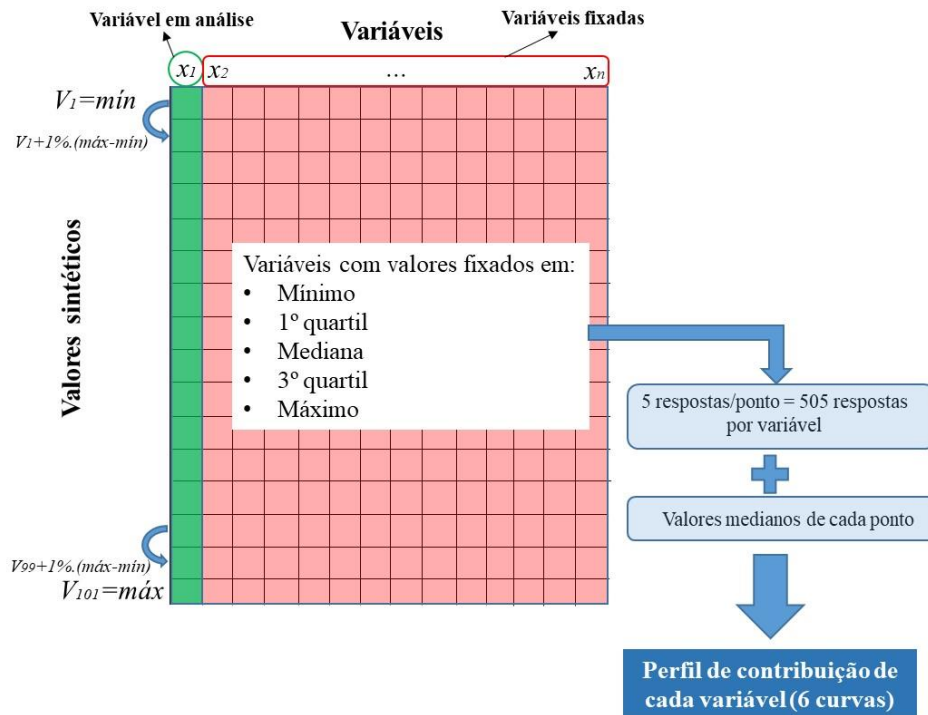
aumento do valor de entrada induz ao aumento e outras vezes à diminuição da variável resposta. A monotonia pode ser avaliada, para cada *input*, por meio da razão  $\mu / \mu^*$ , sendo o valor 1,0 (ou próximo a isso) indicativo de monotonia positiva e -1,0 (ou próximo disso) de monotonia negativa.

### (iii) Perfil de sensibilidade

O método Perfil de sensibilidade foi proposto por Lek (LEK *et al.*, 1995; LEK *et al.*, 1996) e tem como ideia central a investigação sucessiva de cada variável de entrada, quando as demais se mantêm fixas. O princípio é construir uma matriz fictícia referente ao intervalo de todas as variáveis de entrada.

Cada variável teve o *range* entre o valor mínimo e valor máximo dividido em 100 intervalos iguais. Iniciou-se pelo valor mínimo e, sucessivamente, incrementos de 1% foram adicionados. Em paralelo, todas as variáveis, exceto a que estava em análise, foram definidas inicialmente em seus valores mínimos, e sucessivamente no primeiro quartil, mediana, terceiro quartil e máximo.

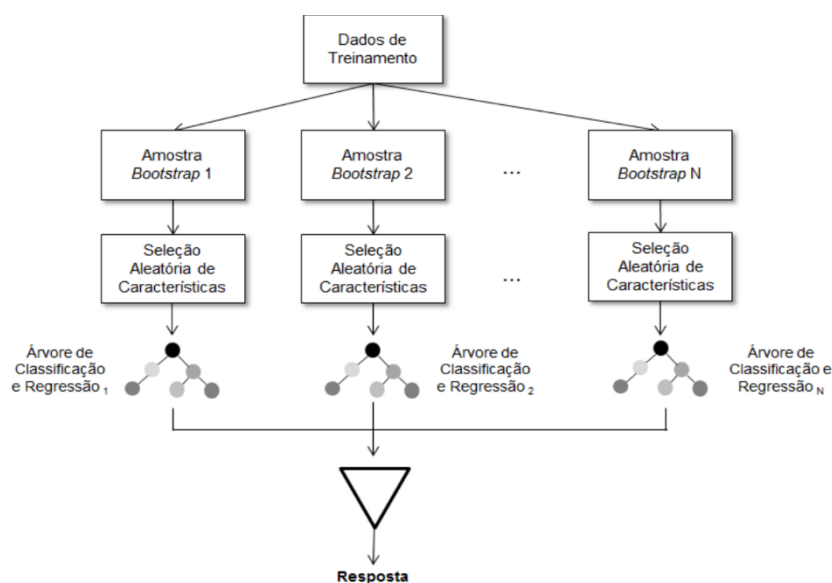
Explicando doutro modo, para cada *input*  $x_i$  são gerados 5 conjuntos de dados sintéticos em que os demais *inputs* são fixados sucessivamente em seus valores mínimos, 1º quartil, medianos, 3º quartil e máximos, enquanto  $x_i$  varia entre seu valor mínimo e máximo, aumentando em incrementos de 1%, de forma que são fornecidos 101 valores sintéticos de  $x_i$  para cada um dos cinco conjuntos de dados. Para cada variável estudada são obtidos cinco valores para cada um dos pontos da escala (de 101 valores), os quais também são convertidos em seu valor mediano. Obtém-se assim, um conjunto de perfis (curvas) de variação da variável dependente de acordo com o aumento da variável de entrada. Esse processo é executado  $n$  vezes, uma vez para cada variável  $x_i$   $\{i=1,2,\dots, n\}$ , sendo  $n$  o número total de variáveis do modelo. Na Figura 5.6 está demonstrado o esquema geral do método.



**Figura 5.6** - Esquema explicativo do método de perfil de sensibilidade  
 Fonte: Gevrey *et al.* (2003) adaptado

(iv) Fator de importância

Para a determinação dos fatores de importância de cada variável explicativa, será empregado *Random Forest* (RF), descrito no item B.1.2. Na Figura 5.7 está apresentado o esquema de funcionamento da RF.



**Figura 5.7** - Esquema geral Random Forest  
 Fonte: Borges Junior (2016)

Uma característica bastante útil dessa técnica é o cálculo explícito de fatores de importância. Segundo Friedman (2001), para toda divisão em cada árvore, a medida de importância da variável discriminante é determinada a partir de seu poder de divisão da classe de interesse e é acumulada em todas as árvores da floresta separadamente para cada variável. São utilizadas amostras *out-of-bag* (subconjunto aleatório de dados não utilizados pelo algoritmo para construção das árvores) para construção de uma medida diferente da importância da variável, para medir a força de predição de cada variável. Quando a  $b$ -ésima árvore é gerada, as amostras *out-of-bag* são processadas pela árvore, e a precisão de previsão é registrada. Em seguida, os valores para a  $j$ -ésima variável são aleatoriamente permutados nas amostras *out-of-bag* e a precisão é novamente calculada. A redução da precisão como resultado desta permuta é calculada, em termos médios, em todas as árvores e é usada como uma medida da importância da variável  $j$  na *Random Forest* (FRIEDMAN, 2001; LENTO, 2017).

Tem-se então, o cálculo da importância relativa de cada variável de entrada, normalizadas, de forma que a soma dos fatores de importância de todas as variáveis resulta em 1,0. Essa medida permite identificar as variáveis mais influentes no modelo, no entanto não é capaz de estabelecer a forma de relacionamento entre o *input* e a variável de saída.

#### (v) Validação estrutural dos modelos MVPLN

Embora não seja tida explicitamente como forma de validação, para os modelos estatísticos o uso dos coeficientes, elasticidade e significância das variáveis são utilizados para investigar os efeitos das variáveis de entrada e fazer inferências.

- *Elasticidade*

Segundo Zhan *et al.* (2015), para avaliar o impacto relativo de cada variável no modelo, a elasticidade da frequência esperada de acidentes  $\lambda$  é obtida. Seguindo a fórmula geral para elasticidade direta, a elasticidade da frequência esperada de acidentes  $\lambda_{is}$  para a observação  $i$  e severidade  $s$  é avaliada da seguinte forma:

$$E = \frac{\partial \lambda_{is}}{\lambda_{is}} \times \frac{x_{ik}}{\partial x_{ik}} = \beta_{sk} x_{ik} \quad (5.14)$$

Em que  $E$  representa a elasticidade;  $x_{ik}$  o valor da  $k$ -ésima variável explanatória para a observação  $i$ ;  $\beta_{sk}$  é o parâmetro estimado para a  $k$ -ésima variável explanatória para a severidade  $s$ ; e,  $\lambda_{is}$  é a frequência esperada de acidentes para a observação  $i$  para o nível de severidade  $s$ .

Uma vez que os valores médios dos parâmetros  $\beta_{sk}$  foram obtidos pela simulação MCMC, a elasticidade é avaliada por essas médias e o valor médio de cada variável explicativa. A partir do valor e do sinal da elasticidade é possível analisar os efeitos de cada variável e compará-los com as expectativas da pesquisa e achados da literatura.

- *Seleção de variáveis*

O conjunto de variáveis empregado para desenvolvimento dos modelos via RNA e MVPLN foi o mesmo e permitiu a comparação entre as duas abordagens. Diante das tentativas de redução de dimensionalidade do problema para posterior emprego das redes neurais, verificou-se queda no desempenho preditivo do modelo; motivo pelo qual foram utilizadas todas as variáveis explicativas entendendo que o modelo tiraria proveito de informações de todas elas para melhorar as previsões.

No caso da abordagem estatística o objetivo é criar um modelo de regressão de alta qualidade que inclua o mínimo de atributos possível, sem comprometer a capacidade preditiva do modelo (KOTU & DESHPANDE, 2015). Tendo isto em conta, foi empregado um método de seleção de variáveis para redução do conjunto de variáveis explicativas.

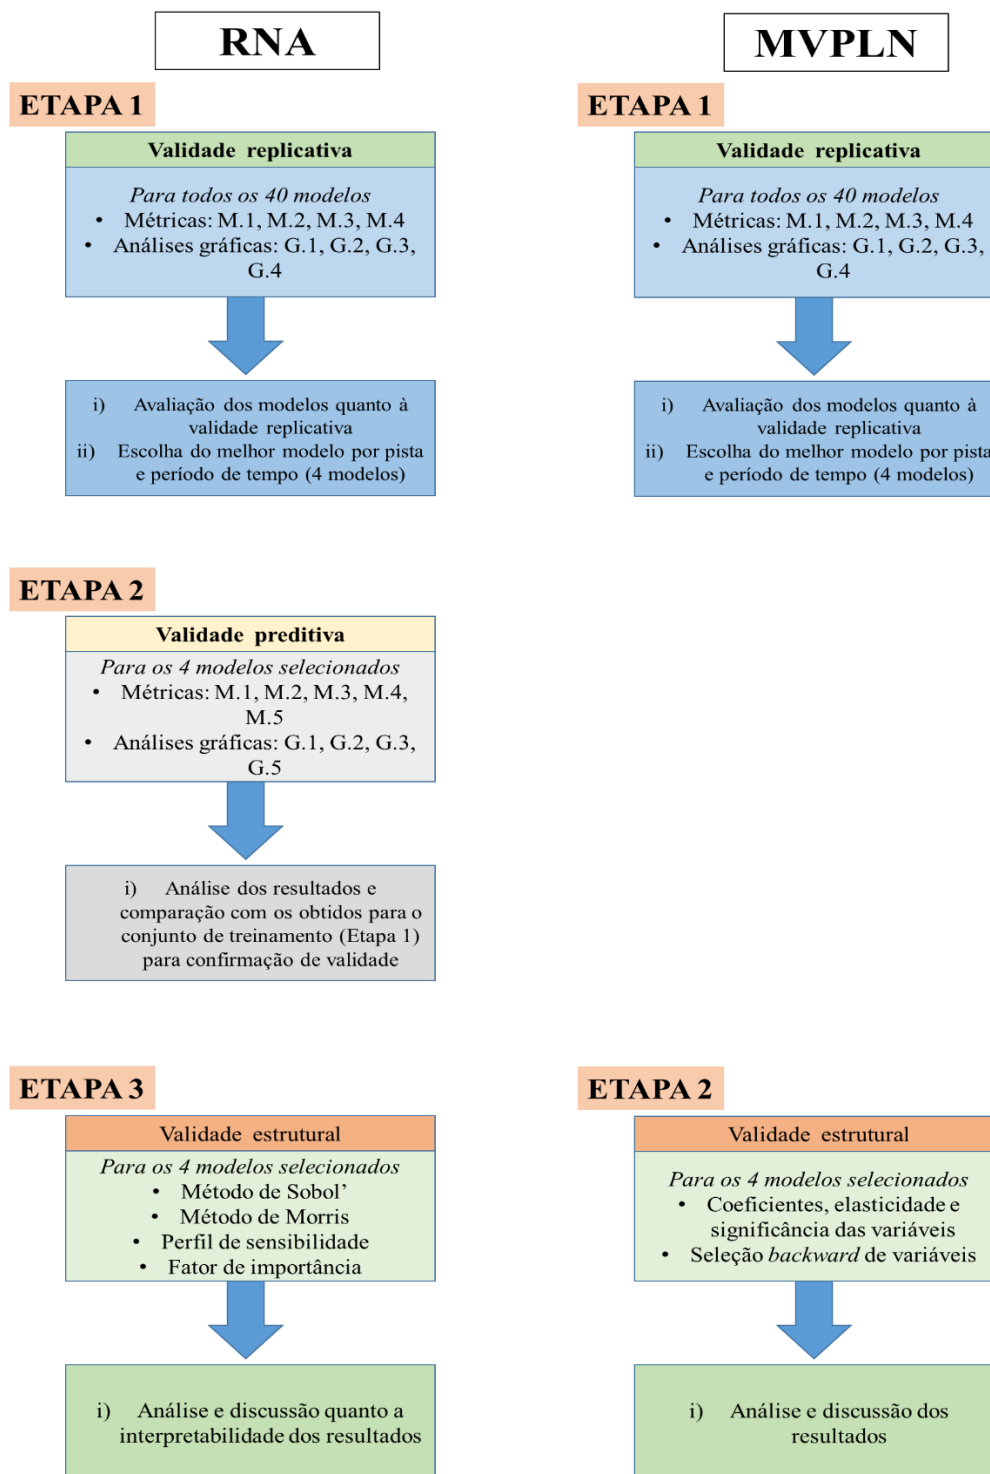
O clássico método de seleção *backward* usando  $p$ -valor foi adotado. Nessa abordagem, inicialmente todas as variáveis são testadas no modelo de regressão e, subsequentemente as variáveis menos significativas são eliminadas, uma a cada passo. O processo é finalizado quando todas as variáveis constantes no modelo são significativas a um nível de significância de 5% (ROYSTON & SAUERBREI, 2008; SANCHEZ-PINTO *et al.*, 2018). Para o caso de uma abordagem multivariada, como no presente estudo, uma adaptação é necessária. Nesta

situação, o critério de parada é quando todas as variáveis do modelo são significativas ( $p < 0,05$ ) para, pelo menos, um nível de severidade.

O processo, que pode ser automatizado para outros modelos estatísticos, teve que ser realizado manualmente com muito tempo e custo computacional empreendidos. A cada passo (nova execução) os resultados tiveram de ser investigados de modo a identificar a variável menos significativa; seguidamente, a exclusão dessa variável implicou na alteração do código computacional, do arquivo de inicialização do modelo e da base de dados como forma de preparação para a próxima execução. O processo foi repetido até que, todas as variáveis incluídas no modelo, fossem significativas ao nível de 0,05 de probabilidade para pelo menos um dos níveis de severidade.

## 6. ANÁLISE DOS RESULTADOS

Neste capítulo são apresentados os resultados e respectivas análises segundo os aspectos de validade replicativa, preditiva e estrutural dos modelos de RNA e MVPLN. O procedimento geral de validação, esmiuçado no Capítulo 5, está esquematicamente apresentado na Figura 6.1.



**Figura 6.1** - Procedimento geral de validação dos modelos

## 6.1. VALIDAÇÃO REPLICATIVA

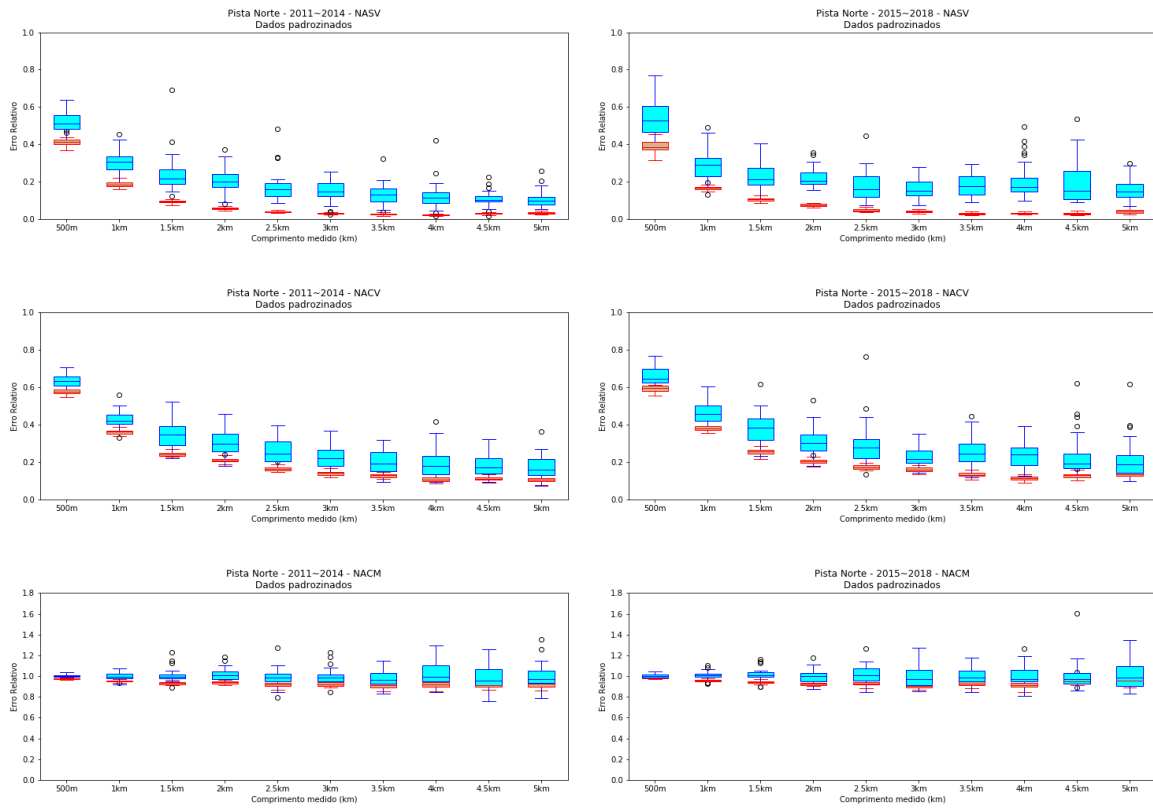
Como já referido no Capítulo 5, buscando avaliar de forma mais completa os modelos e contribuir para a análise de desempenho, são considerados, de forma associada, as métricas de erro (ER, MSLE, MdAPE),  $R^2$ , análise gráfica de resíduos e *CURE Plot*.

### 6.1.1. Redes Neurais Artificiais

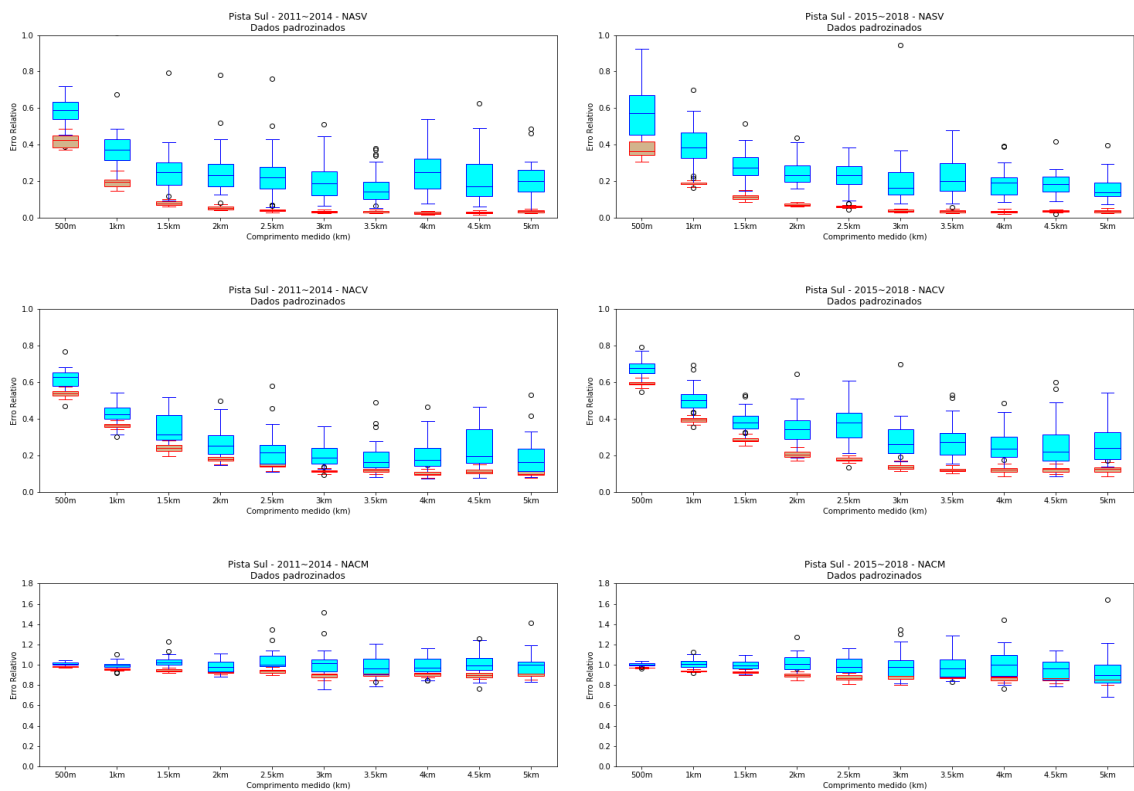
Nesta seção são apresentados os modelos de previsão de acidentes obtidos por meio da aplicação de RNA para segmentos da rodovia BR-116. Para a modelagem foram consideradas três variáveis resposta, ajustadas de forma conjunta, sejam elas: Número de acidentes sem vítimas (*NASV*), Número de acidentes com vítimas (*NACV*) e Número de acidentes com mortes (*NACM*). De outro lado, foi utilizado conjunto de variáveis explanatórias contendo fatores associados ao ambiente viário, operação e pavimento.

Com o objetivo de avaliar a influência da extensão do segmento no ajuste dos modelos, foram consideradas 10 diferentes extensões. E ainda, tendo em consideração dois períodos de tempo e duas pistas de tráfego, foram desenvolvidos modelos para 40 diferentes cenários. Na Figura 6.2 está apresentado o desempenho, em termos de Erro Relativo, dos cenários simulados para a Pista Norte e na Figura 6.3, similarmente, para a Pista Sul. É perceptível a qualidade de ajuste dos modelos, especialmente para *NASV* e *NACV*, com Erro Relativo (ER) próximo de zero, com tendência de redução mediante aumento da extensão do segmento. Por outro lado, verifica-se que todas as execuções, o ER de *NACM* está em torno de um, o que não é desejável. O tratamento específico que foi dado ao número de acidentes totais será tratado mais à frente.

Mesmo diante de indicativos de qualidade de ajuste dos modelos a partir do ER, é necessário analisar outras métricas de erro e comportamento dos resíduos para tal confirmação. Inicialmente foram obtidas e analisadas as medidas apresentadas na Tabela 6.1, que faz referência aos modelos ajustados para a Pista Norte. A escala de cor indica que, célula branca tem o pior desempenho e célula verde escuro o melhor desempenho, na métrica correspondente.



**Figura 6.2** – Erro relativo dos modelos para Pista Norte, com uso de redes neurais



**Figura 6.3** – Erro relativo dos modelos para Pista Sul, com uso de redes neurais



A métrica MSLE, para penalizar menos os erros maiores inerentes ao aumento da extensão do segmento, determina primeiro o logaritmo dos valores reais e previstos, para depois operar como MSE (erro quadrático médio). Como consequência disso, a distância entre os valores, em termos proporcionais, é reduzida. Para essa medida, verificou-se a ocorrência dos valores mínimos junto aos segmentos mais extensos, o que é evidenciado pela escala de cor da tabela.

Outra medida, o MdAPE, diferente dos valores absolutos de erro, tem como resultado o percentual de diferença entre o valor real e previsto, em relação ao valor real. Para minimizar a penalização de valores próximos a zero e amortização dos valores maiores, utilizou-se a mediana dos erros percentuais absolutos. Para esse tipo de erro também ficou evidenciada a concentração dos melhores valores, ou seja, valores percentuais mínimos de erro, junto aos segmentos mais extensos, especialmente de 4,5 km e 5 km.

O Erro Relativo, medida que busca tornar mais comparáveis os resultados de erro, independente da extensão do segmento, similar ao MdAPE, teve a concentração dos valores mínimos nos segmentos mais longos. No período 2011 a 2014, os menores valores auferidos foram no segmento de 5 km, enquanto que para o período de 2015 a 2018 oscilaram entre 3 km, 3,5 km e 4,5 km.

Embora não possa ser tido como uma medida principal, o coeficiente de determinação pode fornecer indicativos do ajuste dos modelos e permitir a comparação entre os diferentes cenários. Assim como as medidas relativas de erro (ER e MdAPE), o  $R^2$  teve seus melhores valores nos segmentos mais longos, especificamente no de 5 km para o período 2011-2014 e 3 km, 4 km e 4,5 km para o período 2015-2018. Já o ER alto e  $R^2$  muito baixo reforçam a dificuldade de ajuste dos modelos para *NACM*.

Destaca-se ainda que, especialmente para *NASV*, notou-se que o segmento de 3,5 km, apesar de não ter os valores mínimos de erro atribuído a ele, é um ponto de mínimo local. Verificou-se que, de uma forma geral, a partir dele, valores de ER e MSLE voltam a crescer e de  $R^2$  tem nova queda. Tais valores estão sublinhados na Tabela 6.1, sendo mais evidente no período de 2011 a 2014. Na Tabela 6.2, de forma análoga, são apresentados os resultados das métricas de erro para a Pista Sul.

**Tabela 6.1 – Medidas de desempenho dos modelos ajustados para Pista Norte, com uso de redes neurais**

Ext. do segmento	PN_2011_2014												PN_2015_2018												
	NASV				NACV				NACM				NASV				NACV				NACM				
	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE
500 m	0,41	39,06	49,92	0,60	0,548	113,45	62,44	0,45	0,97	223,63	0,03	0,44	55,77	52,85	0,56	0,61	129,65	70,41	0,39	0,98	217,34	0,02			
1km	0,20	10,48	31,92	0,81	0,369	56,51	44,53	0,63	0,95	230,79	0,05	0,18	15,17	30,70	0,83	0,38	69,61	47,46	0,62	0,95	227,29	0,05			
1,5 km	0,10	2,00	21,95	0,90	0,253	25,57	34,83	0,75	0,94	228,40	0,06	0,08	5,62	21,27	0,92	0,25	33,47	36,75	0,75	0,94	231,02	0,06			
2 km	0,05	1,49	16,93	0,95	0,194	15,03	30,16	0,81	0,95	224,34	0,05	0,06	1,46	17,08	0,94	0,22	22,65	32,29	0,78	0,92	228,89	0,08			
2,5 km	<u>0,03</u>	0,96	13,90	0,97	0,155	8,42	26,68	0,85	0,95	224,81	0,05	0,06	0,07	12,86	0,95	0,18	11,14	24,92	0,82	0,92	224,03	0,08			
3 km	0,04	0,07	13,17	0,96	0,134	<u>2,22</u>	22,54	0,87	<u>0,90</u>	211,93	<u>0,10</u>	0,04	0,08	13,05	0,96	0,15	8,09	27,21	0,85	<b>0,87</b>	221,02	<b>0,13</b>			
3,5 km	0,04	<u>0,05</u>	11,71	0,96	<u>0,131</u>	2,54	22,18	<u>0,87</u>	0,92	206,52	0,08	<b>0,03</b>	0,06	9,57	<u>0,97</u>	0,14	6,99	24,41	0,86	0,93	217,71	0,07			
4 km	0,03	0,07	10,70	0,97	0,131	1,60	21,11	0,87	0,92	200,91	0,08	0,04	0,04	9,45	0,96	<b>0,11</b>	6,77	<u>21,73</u>	<b>0,89</b>	0,92	218,62	0,08			
4,5 km	0,03	0,04	<b>9,42</b>	0,97	0,112	<b>0,12</b>	20,16	0,89	0,91	188,59	0,09	0,03	<b>0,04</b>	<b>8,49</b>	<b>0,97</b>	0,13	<b>1,63</b>	22,92	0,87	0,94	216,16	0,06			
5 km	<b>0,03</b>	<b>0,04</b>	11,15	<b>0,97</b>	<b>0,111</b>	2,05	<b>19,23</b>	<b>0,89</b>	<b>0,90</b>	<b>185,25</b>	<b>0,10</b>	0,04	0,05	13,17	0,96	0,12	7,38	<b>21,07</b>	0,88	0,97	<b>206,18</b>	0,04			

**Tabela 6.2 - Medidas de desempenho dos modelos ajustados para Pista Sul, com uso de redes neurais**

Ext. do segmento	PS_2011_2014												PS_2015_2018											
	NASV				NACV				NACM				NASV				NACV				NACM			
	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	R <sup>2</sup>		
500 m	0,44	39,89	52,31	0,56	0,54	113,32	65,51	0,46	0,98	222,08	0,02	0,35	63,06	54,89	0,65	0,58	131,69	72,38	0,42	0,97	<b>213,06</b>	0,03		
1km	0,20	10,63	32,50	0,81	0,36	55,50	46,79	0,64	0,96	234,88	0,04	0,19	18,06	32,07	0,81	0,41	74,75	47,25	0,59	0,93	223,19	0,07		
1,5 km	0,08	1,77	24,56	0,92	0,28	31,69	37,72	0,72	0,97	232,23	0,03	0,12	5,11	23,26	0,89	0,32	36,79	39,28	0,68	0,95	228,17	0,05		
2 km	0,06	0,78	19,39	0,94	0,18	21,95	32,68	0,82	0,92	225,11	0,08	0,07	2,14	17,68	0,93	0,22	23,38	32,96	0,78	0,89	230,20	0,11		
2,5 km	0,03	0,96	16,66	0,97	0,12	12,62	25,95	0,88	0,94	220,23	0,06	0,07	1,92	16,66	0,93	0,18	18,45	30,20	0,82	<b>0,85</b>	226,83	<b>0,16</b>		
3 km	0,04	0,08	14,53	0,96	0,10	7,20	23,21	0,90	0,91	218,50	0,09	0,04	0,08	11,86	0,96	0,15	12,11	26,76	0,85	0,95	226,12	0,06		
3,5 km	0,03	0,08	14,70	0,97	0,11	3,76	23,66	0,89	0,94	205,34	0,06	0,05	0,07	10,37	0,95	0,11	7,11	26,49	0,89	0,88	226,66	0,12		
4 km	<b>0,03</b>	<b>0,05</b>	<b>12,01</b>	<b>0,97</b>	<b>0,08</b>	0,17	<b>22,13</b>	<b>0,92</b>	<b>0,87</b>	204,42	<b>0,13</b>	<b>0,03</b>	<b>0,04</b>	<b>8,87</b>	<b>0,97</b>	0,10	5,71	<b>20,13</b>	0,90	0,88	<u>221,45</u>	0,12		
4,5 km	0,03	0,06	12,82	0,97	0,09	0,20	23,24	0,91	0,93	197,56	0,07	0,04	0,05	10,63	0,96	<b>0,10</b>	3,45	20,62	<b>0,90</b>	0,88	222,07	0,13		
5 km	0,03	0,07	15,76	0,97	0,10	<b>0,16</b>	22,24	0,90	0,91	<b>179,08</b>	0,09	0,05	0,05	12,42	0,95	0,16	<b>2,13</b>	24,59	0,84	0,87	213,22	0,13		

Os menores valores de MSLE ocorrem no segmento de 4 km para *NASV* e 5 km para *NACV*, em ambos os períodos de tempo. O MdAPE, por sua vez, tem melhor desempenho basicamente no segmento de 4 km, independente do período temporal. Em termos de ER, fica evidenciado o segmento de 4 km como dotado dos melhores valores, à exceção do *NACM* para o período 2015-2018 em que o menor ER foi auferido no segmento de 2,5 km. Por fim, no período 2011-2014 os maiores valores de  $R^2$  se dão no segmento de 4 km, enquanto que para o período de tempo posterior ocorrem nas extensões de 2,5 km, 4 km ou 4,5 km, a depender da variável resposta.

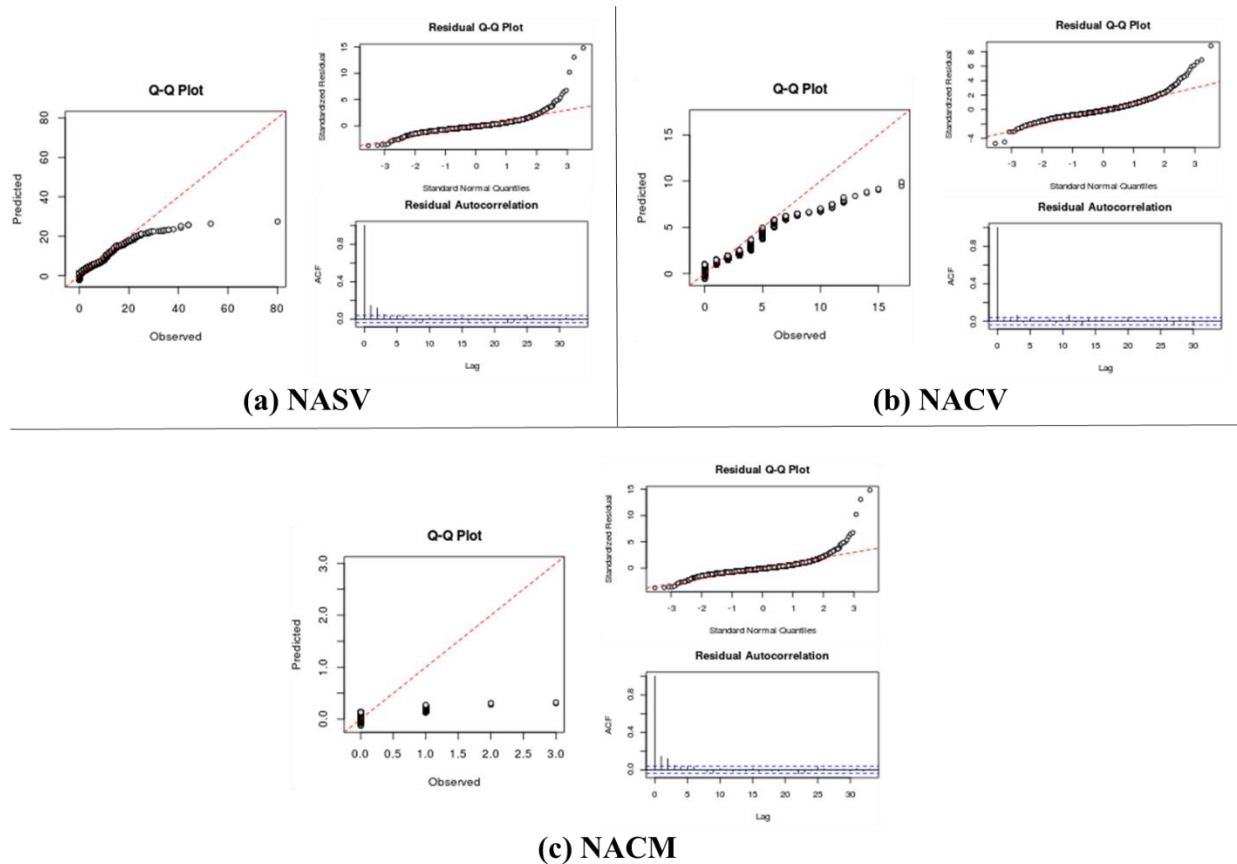
Ademais, como destacado nas tabelas (valores sublinhados), a ocorrência de mínimos locais de MSE, RMSE e MAD, para *NASV* em ambos os períodos, se deu no segmento de 4 km. Deste modo, numa análise conjunta, para a Pista Sul fica evidenciada a predominância dos melhores resultados para a extensão de 4 km, especialmente no período de 2011 a 2014, sugerindo que os melhores modelos ocorrem nesse segmento. No caso da Pista Norte, embora com ligeiras diferenças de desempenho, as métricas de erro e  $R^2$  apontam para extensão a partir de 3,5 km, em ambos os períodos de tempo, como dotadas dos melhores modelos.

Diante das constatações iniciais, restou confirmá-las por meio da análise de resíduos que foi conduzida para todos os modelos desenvolvidos. Os elementos gráficos avaliados foram: gráfico quantil-quantil dos dados observados *versus* previstos (*Q-Q Plot*), gráfico quantil-quantil dos resíduos (*Residual Q-Q Plot*) e gráfico de autocorrelação de resíduos (*Residual Autocorrelation Plot*).

Mediante análise dos gráficos para Pista Norte, verificou-se a inadequação das extensões iniciais de segmento, especialmente de 500 m e 1 km, tendo-se notado: alta dispersão de pontos e, claro padrão no gráfico de dispersão de *NACV*; maior parte dos pontos plotados fora da linha 1:1 do *Q-Q Plot*; inconsistência da normalidade na distribuição dos resíduos; existência de autocorrelação residual; viés nos resíduos padronizados e extrapolação das bandas de confiança. E ainda, para *NACM*, como esperado, não foi verificada a adequação dos resíduos. Comentários específicos quanto as previsões do número de acidentes fatais são tecidas no decurso deste capítulo.

A título de exemplo de resultado, na Figura 6.4 são apresentados os gráficos correspondentes ao modelo de segmento de 500 m da Pista Norte para o período de 2011-2014. As figuras

relativas a outros modelos, que incluem também elementos gráficos complementares (gráfico de dispersão de dados observados *versus* previstos - *Scatter Plot* -, gráfico de dados observados e previstos - *Observed vs Predicted* -, histograma de resíduos, gráfico de autocorrelação parcial de resíduos - *Residual Partial-Autocorrelation Plot* -, gráfico de resíduos padronizados *versus* valores previstos - *Residual vs Simulated* - e gráfico de resíduos padronizados na ordem dos dados - *Residuals vs Order/Time* -, estão apresentadas no Apêndice C.



**Figura 6.4** – Qualidade de ajuste e análise de resíduos para PN\_500m\_2011\_2014 (RNA)

A partir da Figura 6.4, iniciando a análise pelo *Q-Q Plot*, em que a convergência de distribuição dos valores observados e previstos é revelada pela disposição dos pontos ao longo da linha 1:1, nota-se que tanto para *NASV* quanto para *NACV* existem grandes desvios em relação à linha de 45°, o que não é um comportamento desejável. Tais desvios a partir de  $NASV = 20$  e  $NACV = 5$  indicam viés de subestimação do modelo na previsão de valores superiores a estes patamares. Já em termos dos resíduos, buscando verificar a consistência destes com a distribuição normal, é apresentado o *Residual Q-Q Plot*. Quando os resíduos são normalmente distribuídos, encontram-se ao longo ou próximo à linha reta apresentada no gráfico. Observa-se na Figura 6.4 que em todos os casos, existem desvios no início e final da reta, o que remete à existência

de valores extremos. Por fim, o *Residual Autocorrelation* avalia a autocorrelação dos resíduos por meio de uma função de autocorrelação (ACF). A correlação é considerada nula se os valores de ACF estiverem dentro das faixas de confiança de 95% em torno de zero. Pelos gráficos da Figura 6.4 se observa a extrapolação dessas bandas limítrofes aceitáveis para o *NASV* e *NACM*, sinalizando para existência de correlação dos resíduos e comprometimento do desempenho do modelo. Na Tabela 6.3 está apresentada a síntese dos resultados de todos os modelos da Pista Norte.

**Tabela 6.3** - Síntese dos resultados da análise gráfica dos modelos da Pista Norte (RNA)

Modelo	<i>Q-Q Plot</i> (2011-2014/2015-2018)	<i>Residual Q-Q Plot</i> (2011-2014/2015-2018)	<i>Residual autocorrelation</i> (2011-2014/2015-2018)
PN_500m	GD/GD	DI-IF/DI-IF	Auto-NASV e NACM/Auto-B
PN_1km	GD/GD	DI-IF/DI-IF	Auto-NASV/Auto-B
PN_1,5km	GD/GD	DI-IF/DI-IF	Auto-MB/Auto-NASV
PN_2km	GD/GD	DI-IF/DI-IF	Auto-MB/Auto-MB
PN_2,5km	MD/MD	DI-IF/DI-IF	Auto-MB/Auto-MB
PN_3km	MD/MD	DM-IF/DM-IF	Auto-MB/Auto-MB
PN_3,5km	PD/PD	PD-IF/DM-IF	Auto-MB/Auto-MB
PN_4km	MD/PD	PD-IF/PD-IF	Auto-MB/Auto-B
PN_4,5km	PD/PD	PD-/PD-IF	Auto-MB/Auto-MB
PN_5km	PD/PD	PD-IF/PD-IF	Auto-MB/Auto-MB

Legenda: GD: grandes desvios; MD: médios desvios; PD: pequenos desvios; DI-IF: desvios importantes no início e final da linha; DM-IF: desvios médios no início e final da linha; PD-IF: pequenos desvios no início e final da linha; Auto-NASV e NACM: existência de autocorrelação de resíduos para NASV e NACM; Auto-NASV: existência de autocorrelação de resíduos para NASV; Auto-B: autocorrelação baixa; Auto-MB: autocorrelação muito baixa ou inexistente.

A qualidade de ajuste e comportamento dos resíduos tornam-se mais adequados a partir da extensão de 2,5 km, no entanto, os segmentos de 3 km a 4,5 km é que possuem melhor ajuste. Entre essas extensões as diferenças são sutis, não havendo prejuízo na escolha de qualquer uma delas. Mesmo assim, valendo-se de maior rigor de análise e tendo em conta as constatações anteriores, com base nas métricas de erro, constatou-se maior adequação do segmento de 3,5 km para a Pista Norte, em ambos os períodos de tempo. No Apêndice C estão apresentados os respectivos resultados gráficos.

A razoabilidade da qualidade de ajuste para *NASV* e *NACV* é clara em todos os gráficos (*Scatter Plot*, *Q-Q Plot* e *Observed vs Predicted*), estando os pontos distribuídos em padrão aceitável. Os raros pontos distantes do final da reta, podem indicar a existência de algum valor discrepante, mas não comprometem a qualidade de ajuste. Em termos de análise de resíduos, pode-se admitir a normalidade na distribuição dos resíduos, mesmo diante da ocorrência de

alguns desvios no início e final da linha (remetendo a hipótese de valores discrepantes). Nota-se a concentração de resíduos padronizados entre 0 e 50 acidentes sem vítimas e de 0 a 30 acidentes com vítimas, sendo reflexo da distribuição original dos dados observados e não de viés dos resultados. Constatou-se ainda, o atendimento à recomendação de que cerca de 95% dos resíduos padronizados estejam dentro das faixas de confiança, especialmente no período 2015-2018. Por fim, mediante análise dos *Residual Autocorrelation Plot*, descartou-se a possibilidade de autocorrelação dos resíduos.

À vista disso, para os modelos escolhidos, em termos de validade replicativa, pode-se afirmar que o desempenho do modelo é de alta magnitude, com pequenos desvios, convergência entre valores observados e previstos, aceitação de normalidade de distribuição dos resíduos, dispersão aceitável dos resíduos padronizados e ausência de autocorrelação nos resíduos.

Para o caso dos modelos da Pista Sul está apresentada a Tabela 6.4. De forma semelhante, os segmentos de 500 m, 1 km e 1,5 km apresentaram alta dispersão de pontos e nítido padrão na distribuição comparativa entre valores observados e previstos de *NACV*; grande quantidade de pontos fora da linha 1:1 do *Q-Q Plot*; não aceitação de distribuição gaussiana dos resíduos; existência de autocorrelação residual; viés nos resíduos padronizados e extrapolação das bandas de confiança. Essas constatações apontam para inadequação desses modelos, independente do período de tempo analisado.

**Tabela 6.4** – Síntese dos resultados da análise gráfica dos modelos da Pista Sul (RNA)

Modelo	<i>Q-Q Plot</i> (2011-2014/2015-2018)	<i>Residual Q-Q Plot</i> (2011-2014/2015-2018)	<i>Residual autocorrelation</i> (2011-2014/2015-2018)
PS_500m	GD/GD	DI-IF/DI-IF	Auto-NASV e NACV/Auto-NASV e NACV
PS_1km	GD/GD	DI-IF/DI-IF	Auto-MB/Auto-NASV e NACV
PS_1,5km	GD/GD	DI-IF/DI-IF	Auto-MB/Auto-MB
PS_2km	MD/GD	DM-IF/DI-IF	Auto-MB/Auto-MB
PS_2,5km	MD/MD	DM-IF/DM-IF	Auto-MB/Auto-MB
PS_3km	MD/MD	DM-IF/DM-IF	Auto-MB/Auto-MB
PS_3,5km	PD/MD	PD-IF/PD-IF	Auto-MB/Auto-MB
PS_4km	PD/PD	PD-IF/PD-IF	Auto-MB/Auto-MB
PS_4,5km	PD/PD	PD-/PD-IF	Auto-MB/Auto-MB
PS_5km	PD/PD	PD-IF/PD-IF	Auto-MB/Auto-MB

Legenda: GD: grandes desvios; MD: médios desvios; PD: pequenos desvios; DI-IF: desvios importantes no início e final da linha; DM-IF: desvios médios no início e final da linha; PD-IF: pequenos desvios no início e final da linha; Auto-NASV e NACV: existência de autocorrelação de resíduos para NASV e NACV; Auto-B: autocorrelação baixa; Auto-MB: autocorrelação muito baixa ou inexistente.

Igualmente à Pista Norte, a partir da extensão 2,5 km o comportamento dos resíduos e qualidade de ajuste tornam-se mais aceitáveis sendo, entretanto, verificada maior adequação dos resultados para os segmentos de 3,5 km, 4 km e 4,5 km. Tendo em conta os apontamentos da análise inicial de erros e as ligeiras diferenças de desempenho, optou-se pela utilização do segmento de 4 km como o melhor modelo para a Pista Sul, tanto de 2011 a 2014 quanto de 2015 a 2018. No período 2011-2014, para *NASV*, tem-se um ajuste excelente no *Q-Q Plot*; no período posterior, o ajuste também é muito bom, ocorrendo alguns desvios. Para *NACV* o ajuste é bom, notando-se pequenos desvios no *Q-Q Plot* em ambos períodos de tempo. Os gráficos de valores observados e previstos também remetem à convergência dos resultados.

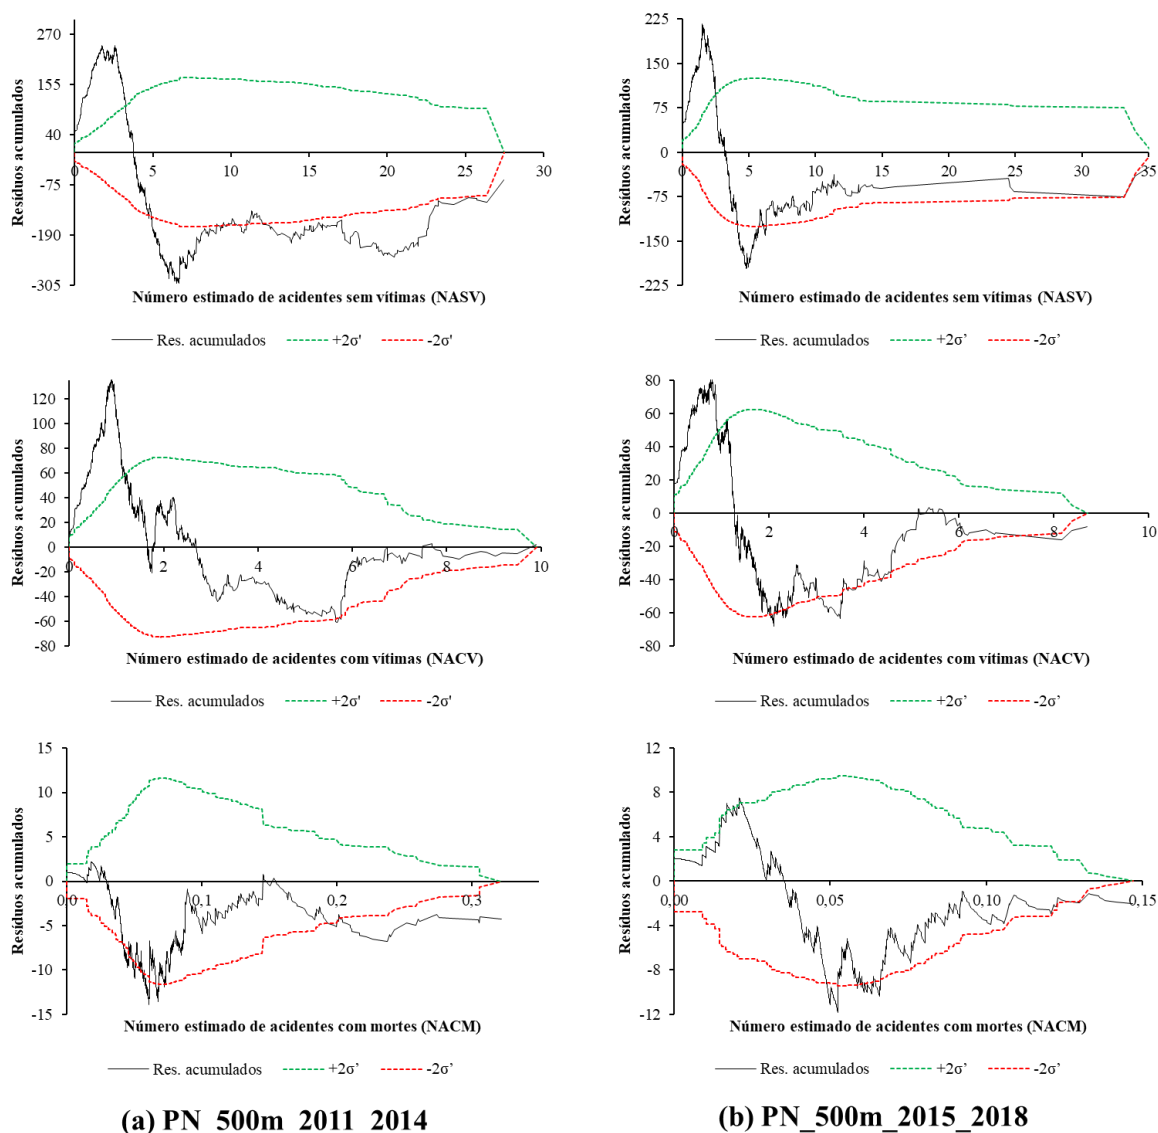
Quanto à análise de resíduos, é aceita a suposição de normalidade na distribuição dos resíduos, identificando-se pequenos desvios no *Residual Q-Q Plot*, especialmente de 2015 a 2018. Os resíduos padronizados, situam-se em torno de zero e atendem razoavelmente aos limites de confiança dos gráficos *Residuals vs Simulated* e *Residual vs Order/Time*. E ainda, os modelos atenderam à recomendação de que 95% dos valores ACF estivessem dentro dos limites, desconsiderando-se então a autocorrelação nos resíduos.

Assim, os modelos adotados podem ser classificados como de desempenho de alta magnitude, com médios desvios, convergência entre valores observados e previstos, aceitação de normalidade de distribuição dos resíduos, dispersão aceitável dos resíduos padronizados e ausência de autocorrelação nos resíduos.

Para fins de confirmação da qualidade de ajuste do modelo, foram também avaliados os *CURE Plot* de cada modelo escolhido. É possível, a partir desse tipo gráfico, analisar os resíduos acumulados em função da variável de interesse, sendo esperada a sua oscilação em torno de zero e dentro dos limites estabelecidos. Conforme Hauer (2015), para modelos com muitas variáveis explicativas, como o caso em tela, os *CURE Plot* devem ser preparados com base nos valores ajustados. Nesse sentido, o gráfico refletirá quão bem ou mal o modelo prevê, não para determinada variável, mas de maneira global, o número de acidentes.

Inicialmente deve-se destacar que, conforme verificada anteriormente, a inadequação dos segmentos mais curtos (em termos de qualidade de ajuste e análise de resíduos), mediante análise dos *CURE Plot* foram obtidas as mesmas constatações. Na Figura 6.5(a), a título de exemplo, são apresentados os gráficos de resíduos acumulados para cada variável resposta

(NASV, NACV e NACM) para o segmento de 500 m da Pista Norte, no período de 2011 a 2014. Os resíduos acumulados não respeitam as envoltórias limítrofes, estando quase totalmente fora delas para o caso de NASV. Comportamento similar é observado para a mesma extensão de segmento, porém no período 2015-2018, conforme Figura 6.5(b). Tais discrepâncias remetem à existência de quantidade excessiva de valores altos de resíduos e regiões de super e subestimação de valores, o que torna tais modelos inaceitáveis.

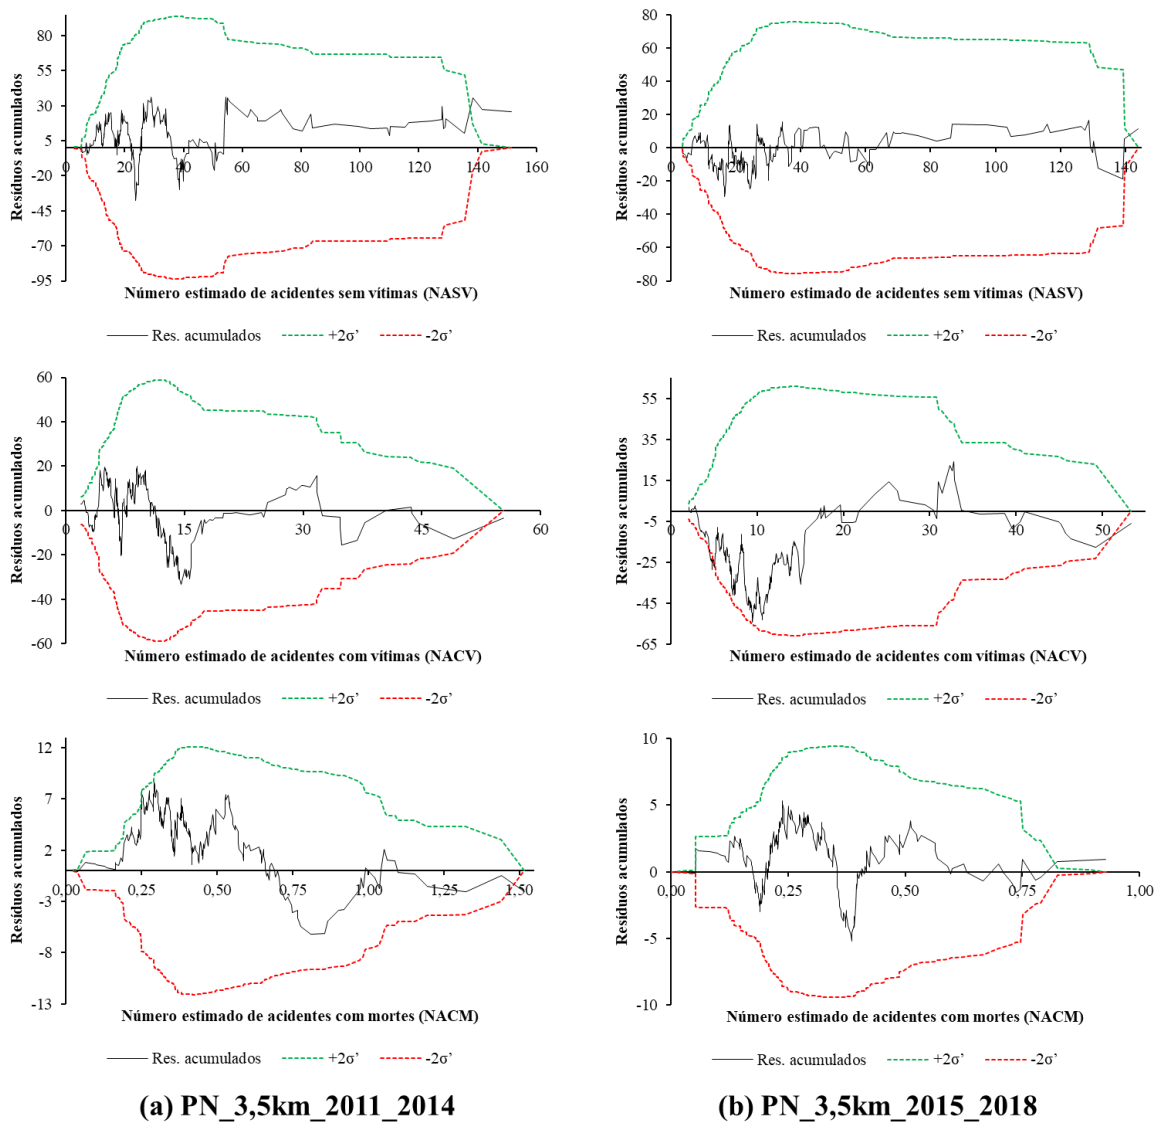


**Figura 6.5 – CURE Plot (RNA) – Pista Norte, 500 m**

Doutro lado, na Figura 6.6 estão apresentados os *CURE Plot* para a extensão de segmento de 3,5 km para ambos períodos de tempo. A análise gráfica confirma a acertada escolha de tais modelos, visto que, os resíduos acumulados estão razoavelmente distribuídos em torno do eixo horizontal e respeitam os limites de confiança para todas as variáveis resposta.

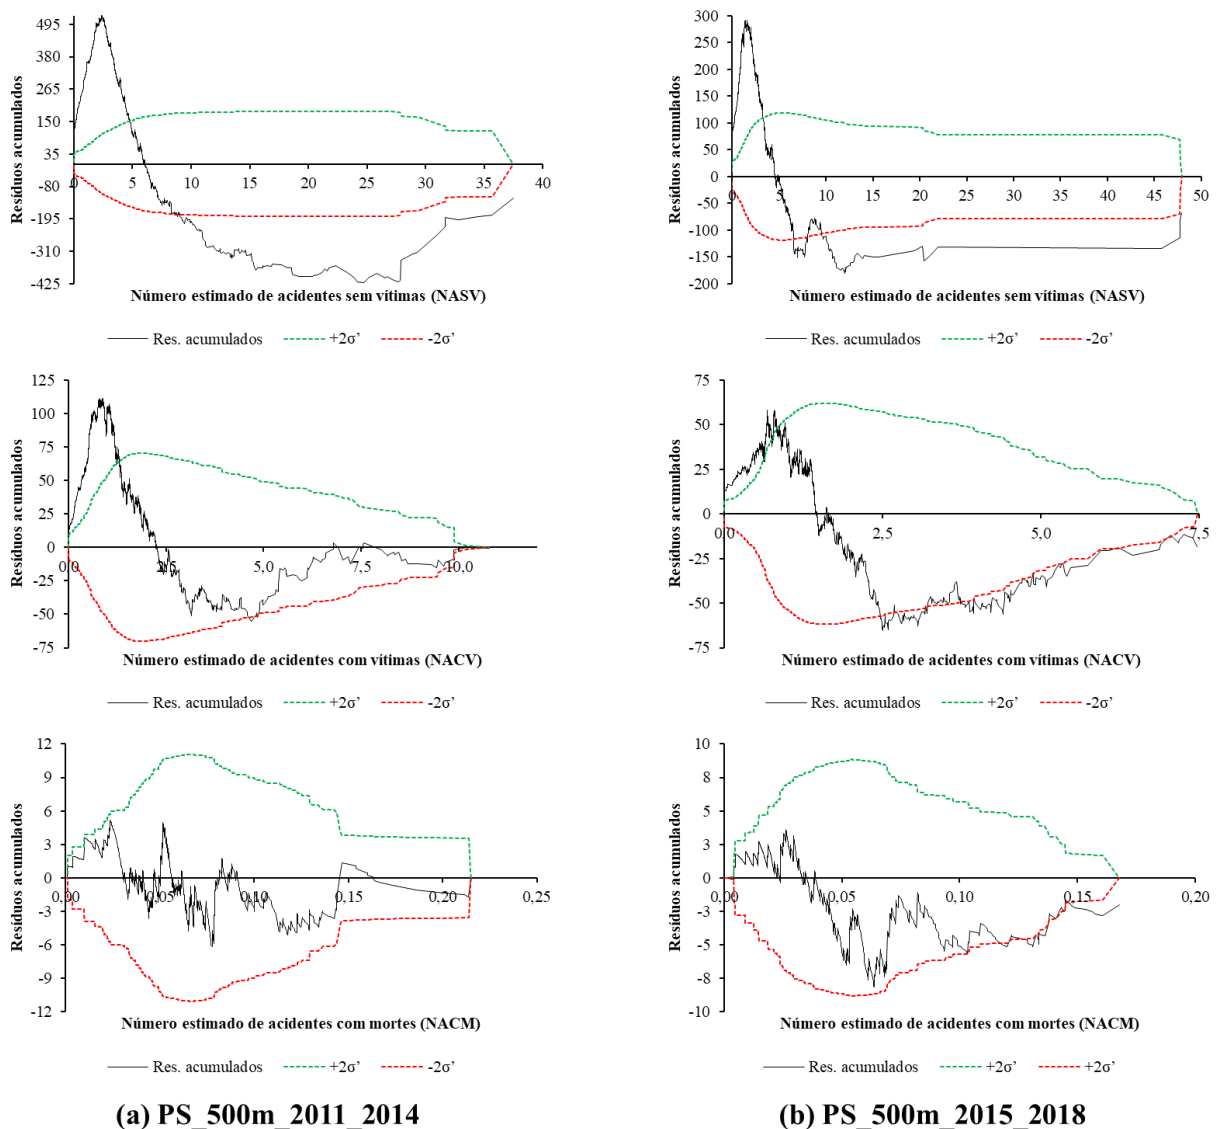


Em ambos os casos, fora identificada ligeira extrapolação da curva de resíduos acumulados ao limite superior, para *NASV* e, ao limite inferior para *NACV*. Tais ocorrências se dão no final da curva e para os maiores valores previstos de acidentes, remetendo à qualidade global do modelo para previsão de acidentes, mas dificuldade de ajuste aos pontos onde possivelmente existe a acumulação de acidentes. Dessa maneira, e ainda considerando que 95% da massa de probabilidade deve estar dentro de dois desvios-padrões para consistência de distribuição normal dos resíduos, tem-se que a ocorrência de raros pontos fora dos limites, como neste caso, não devem motivar a rejeição dos modelos. Ainda assim, ressalta-se que a utilização dos modelos deve ser considerada com cautela para segmentos com valores estimados superiores a 60, que podem ser alvo de subestimação.



**Figura 6.6 – CURE Plot (RNA) – Pista Norte, 3,5 km**

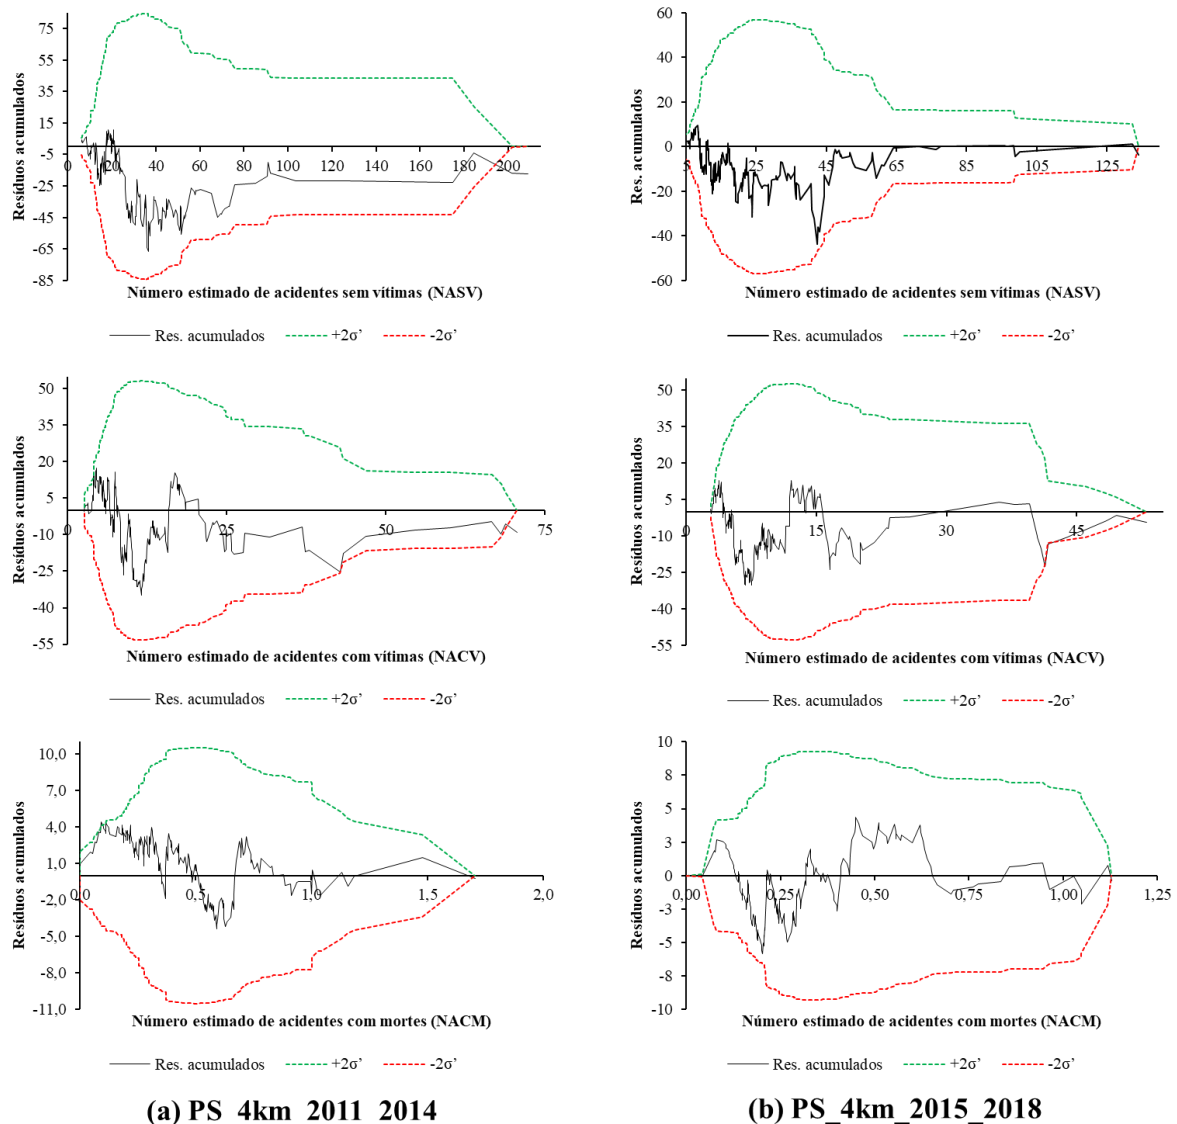
Para a Pista Sul, sob a ótica de qualidade dos *CURE Plot*, constata-se total inadequação dos modelos mais curtos. A Figura 6.7 apresenta os gráficos para os segmentos de 500 m para o período 2011-2014 e 2015-2018. Em ambos os casos, os resíduos acumulados estavam fora das bandas limítrofes em ampla faixa de número de acidentes sem vítimas e número de acidentes com vítimas. Esse comportamento de variação dos resíduos acumulados remete a um padrão de enviesamento sistemático dos modelos, implicando na rejeição destes. Resultados estes que corroboram com as constatações iniciais da qualidade de ajuste e análise de resíduos.



**Figura 6.7 – CURE Plot (RNA) – Pista Sul, 500m**

A melhoria da qualidade dos *CURE Plot* é observada com o aumento da extensão do segmento, constatando-se melhor adequação do segmento de 4 km para ambos períodos de tempo. Os resultados gráficos correspondentes estão apresentados na Figura 6.8. A linha de variação dos

resíduos acumulados oscila, razoavelmente, em torno de zero para o *NACV*, padrão não tão nítido para o *NASV*. Ainda assim, com exceção dos valores extremos de *NASV* e *NACV*, os resíduos acumulados mantêm-se dentro dos limites  $\pm 2\sigma'$ , confirmando a adequação dos modelos.



**Figura 6. 8 – CURE Plot (RNA) – Pista Sul, 4 km**

À luz do exposto, a análise conjunta de erros e análise de resíduos, incluindo o *CURE Plot*, possibilitou escolher o segmento de 3,5 km como melhor modelo para Pista Norte e o segmento de 4 km como melhor modelo para Pista Sul.

### 6.1.2. Modelo Multivariado Poisson lognormal

Neste item são apresentados resultados obtidos mediante emprego do modelo multivariado Poisson lognormal (MVPLN), técnica estatística que tem sido empregada para a previsão conjunta de acidentes, em diferentes níveis de severidade. A aplicação dessa técnica, embora requeira exaustivo trabalho, foi realizada apenas para fins de comparação com os resultados provenientes das RNA, foco do estudo.

Aos resultados obtidos foram aplicadas as mesmas análises procedidas aos modelos resultantes de RNA. A princípio foram observados os valores das medidas de erro, conforme apresentado na Tabela 6.5, referente a Pista Norte. O comportamento verificado nos resultados é similar aos obtidos com uso de redes neurais. O MSLE teve seus menores valores para os segmentos de 4,5 km e 5 km, o mesmo verificado para MdAPE. Já os melhores valores de ER ocorreram para os segmentos de 4 km, 4,5 km e 5 km. Por fim, o  $R^2$  teve valores maximizados para a extensão de 5 km, contando ainda com máximos locais em 3 km e 3,5 km.

Similarmente, na Tabela 6.6 estão apresentados os resultados das métricas de erro para a Pista Sul, para os períodos 2011-2014 e 2015-2018. Nota-se o comportamento típico de valores mínimos de MSLE no segmento de 5 km, enquanto MdAPE, ER e  $R^2$  têm melhor desempenho nos segmentos de 4 km e 5 km. Os resultados de erros relativos apontam para melhor desempenho de segmentos com maior extensão, o que foi verificado também na avaliação de qualidade de ajuste e análise de resíduos. Observou-se, semelhantemente às RNA, a ocorrência da inadequação dos modelos dos segmentos mais curtos, ficando evidente a alta autocorrelação entre os resíduos e viés de comportamento.

Como já referido, os elementos gráficos completos estão apresentados no Apêndice C. De todo modo, na Tabelas 6.7 está apresentada a síntese dos resultados de análise gráfica dos modelos da Pista Norte. Nos segmentos mais extensos, especialmente de 3,5 km a 4,5 km, a qualidade de ajuste é notavelmente melhor. Ainda que com desempenho bastante similar e neutralidade na adoção de qualquer uma das três referidas extensões, optou-se pela escolha do segmento de 3,5 km como melhor modelo, por se mostrar ligeiramente superior.

**Tabela 6.5** – Medidas de desempenho dos modelos ajustados para Pista Norte, com uso de MVPLN

Ext. do segmento	PN_2011_2014											PN_2015_2018										
	NASV				NACV				NACM			NASV				NACV				NACM		
	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	R <sup>2</sup>
500 m	0.28	40.42	35.66	0.72	0.43	113.94	56.47	0.57	0.95	223.55	0.05	0.25	57.64	39.76	0.76	0.44	128.87	62.78	0.57	0.97	214.86	0.03
1km	0.22	11.12	26.47	0.78	0.29	56.19	38.67	0.71	0.91	230.24	0.09	0.15	16.36	29.03	0.85	0.30	68.29	42.67	0.70	0.95	227.88	0.05
1,5 km	0.19	2.08	23.09	0.81	0.21	26.67	31.38	0.79	0.88	229.18	0.12	0.12	4.50	22.38	0.88	0.22	32.89	32.59	0.78	0.92	230.20	0.08
2 km	0.15	1.19	19.10	0.85	0.19	14.60	27.38	0.81	0.87	224.72	0.13	0.11	1.77	20.95	0.89	0.18	21.66	28.21	0.82	0.90	230.97	0.11
2,5 km	0.14	0.81	17.59	0.86	0.16	7.43	25.17	0.84	0.85	218.80	0.16	0.09	0.10	19.31	0.91	0.16	13.08	25.46	0.84	0.91	226.03	0.09
3 km	0.12	0.07	17.20	0.88	0.14	5.05	22.25	0.86	0.86	209.86	0.15	0.08	0.09	18.14	0.92	0.14	<u>7.17</u>	23.33	0.86	<u>0.86</u>	226.02	<u>0.14</u>
3,5 km	0.12	0.08	15.68	0.88	0.13	2.04	19.81	0.87	<u>0.81</u>	206.59	<u>0.19</u>	0.07	0.08	16.67	0.93	0.12	8.47	22.19	0.88	0.89	218.33	0.12
4 km	0.11	0.06	12.88	0.89	0.11	1.22	<u>17.63</u>	0.89	0.84	200.88	0.16	0.08	0.07	14.51	0.92	0.10	5.45	19.08	0.90	<b>0.84</b>	213.40	<b>0.17</b>
4,5 km	<b>0.09</b>	0.05	<b>11.18</b>	<b>0.91</b>	0.12	<b>0.11</b>	19.19	0.89	0.82	190.36	0.19	0.06	0.06	<b>12.18</b>	0.94	0.10	<b>1.30</b>	<b>18.17</b>	0.90	0.89	211.32	0.11
5 km	0.10	<b>0.05</b>	12.26	0.90	<b>0.11</b>	1.54	<b>17.18</b>	<b>0.89</b>	<b>0.80</b>	<b>182.37</b>	<b>0.20</b>	<b>0.05</b>	<b>0.04</b>	12.74	<b>0.95</b>	<b>0.10</b>	5.73	18.84	<b>0.90</b>	0.90	<b>204.79</b>	0.10

**Tabela 6.6** – Medidas de desempenho dos modelos ajustados para Pista Sul, com uso de MVPLN

Ext. do segmento	PS_2011_2014											PS_2015_2018										
	NASV				NACV				NACM			NASV				NACV				NACM		
	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	R <sup>2</sup>
500 m	0.38	41.53	38.71	0.62	0.40	116.04	56.33	0.60	0.97	223.94	0.04	0.22	62.78	41.87	0.78	0.42	131.41	63.80	0.58	0.96	209.38	0.04
1km	0.33	10.76	26.91	0.67	0.28	55.79	42.00	0.72	0.92	232.53	0.09	0.17	17.84	29.67	0.83	0.30	73.00	42.20	0.70	0.93	222.98	0.07
1,5 km	0.22	1.76	25.23	0.78	0.20	32.18	32.46	0.80	0.92	231.90	0.09	0.14	5.23	23.98	0.86	0.24	38.35	35.83	0.77	0.90	228.10	0.10
2 km	0.23	<u>0.68</u>	20.89	0.77	0.17	22.22	29.98	0.83	0.91	227.10	0.10	0.12	1.82	21.47	0.88	0.20	24.04	30.39	0.80	0.87	227.82	0.13
2,5 km	0.21	0.80	19.36	0.79	0.15	12.73	24.31	0.85	0.91	220.11	0.10	0.12	1.49	20.85	0.88	0.19	15.71	29.10	0.81	0.83	225.21	0.17
3 km	0.17	0.10	18.71	0.83	0.13	6.69	23.93	0.87	0.85	214.04	0.16	0.10	0.11	19.14	0.90	0.15	11.37	24.10	0.85	0.84	226.66	0.16
3,5 km	0.15	0.08	17.35	0.85	0.12	3.00	22.40	0.88	<u>0.84</u>	201.55	0.17	0.09	0.11	17.23	0.91	0.14	6.73	23.37	0.86	0.83	223.10	0.17
4 km	<b>0.14</b>	0.08	<b>16.26</b>	<b>0.86</b>	0.11	<u>0.17</u>	20.56	0.89	0.85	201.15	0.16	0.08	0.07	16.60	0.92	0.14	5.68	21.55	0.86	<u>0.80</u>	216.82	<u>0.20</u>
4,5 km	0.15	0.07	17.16	0.85	0.11	1.39	20.21	0.89	0.82	194.49	0.19	0.08	0.07	16.35	0.92	0.13	2.72	20.58	0.87	0.81	212.20	0.19
5 km	0.18	<b>0.07</b>	17.90	0.83	<b>0.10</b>	<b>0.13</b>	<b>19.08</b>	<b>0.90</b>	<b>0.80</b>	<b>184.27</b>	<b>0.21</b>	<b>0.07</b>	<b>0.06</b>	<b>15.64</b>	<b>0.93</b>	<b>0.12</b>	<b>1.54</b>	<b>19.70</b>	<b>0.88</b>	<b>0.77</b>	<b>205.19</b>	<b>0.23</b>

**Tabela 6. 7– Síntese dos resultados da análise gráfica dos modelos da Pista Norte (MVPLN)**

Modelo	<i>Q-Q Plot</i> (2011-2014/2015-2018)	<i>Residual Q-Q Plot</i> (2011-2014/2015-2018)	<i>Residual autocorrelation</i> (2011-2014/2015-2018)
PN_500m	GD/GD	DI-IF/DI-IF	+Auto-NASV/+Auto-NASV
PN_1km	GD/GD	DI-IF/DI-IF	+Auto-NASV/Auto-B
PN_1,5km	GD/GD	DI-IF/DI-IF	+Auto-NASV/Auto-B
PN_2km	GD/MD	DI-IF/DI-IF	+Auto-NASV/Auto-MB
PN_2,5km	GD/MD	DI-IF/DI-IF	Auto-NASV/Auto-B
PN_3km	GD/MD	DM-IF/DM-IF	Auto-MB/Auto-MB
PN_3,5km	MD/PD	DM-IF/DM-IF	Auto-MB/Auto-MB
PN_4km	MD/PD	DM-IF/PD-IF	Auto-MB/Auto-B
PN_4,5km	MD/PD	DM-/PD-IF	Auto-MB/Auto-B
PN_5km	MD/PD	DM-IF/PD-IF	Auto-MB/Auto-B

Legenda: GD: grandes desvios; MD: médios desvios; PD: pequenos desvios; DI-IF: desvios importantes no início e final da linha; DM-IF: desvios médios no início e final da linha; PD-IF: pequenos desvios no início e final da linha; +Auto-NASV: existência de elevada autocorrelação de resíduos para NASV; Auto-NASV: existência de autocorrelação de resíduos para NASV; Auto-B: autocorrelação baixa; Auto-MB: autocorrelação muito baixa ou inexistente.

No período 2011-2014, para *NASV* e *NACV*, tem-se um ajuste razoável do gráfico de dispersão e *Q-Q Plot*, notando-se, entretanto, desvios médios a altos, especialmente neste último gráfico. De 2015 a 2018 vê-se melhor ajuste, mesmo que com pequenos desvios em ambos os gráficos. Quanto à análise de resíduos, pode-se admitir que a distribuição dos resíduos se aproxima da normal, mesmo diante dos desvios no final da linha do *Residual Q-Q Plot*, apontando para existência de *outliers*. Tal constatação é reforçada pelos gráficos de resíduos padronizados (*Residuals vs Simulated* e *Residual vs Order/Time*), nos quais nota-se claramente a distribuição dos resíduos em torno de zero e respeito aos limites aceitáveis, mas, apresentando raros pontos discrepantes. Por fim, o *Residual Autocorrelation Plot* revelou a existência de baixa autocorrelação nos resíduos em todos os casos.

Deste modo, os modelos adotados podem ser classificados como de desempenho de média magnitude, com médios a grandes desvios, convergência entre valores observados e previstos, aceitação de normalidade de distribuição dos resíduos, dispersão aceitável dos resíduos padronizados e baixa de autocorrelação nos resíduos.

No caso da Pista Sul tem-se a síntese apresentada na Tabela 6.8. Os segmentos mais curtos (até 1,5 km) apresentaram alta dispersão de pontos e nítido padrão no *Scatter Plot* de *NACV*; grande quantidade de pontos fora da linha 1:1 do *Q-Q Plot*, especialmente para *NACV*; existência de considerável autocorrelação residual; viés nos resíduos padronizados e extrapolação das bandas de confiança. Tais características implicam na rejeição desses modelos. Estão apresentados no

Apêndice C, os gráficos da qualidade de ajuste e análise residual correspondentes aos modelos de segmento de 500 m da Pista Sul para os períodos de 2011-2014 e 2015-2018, respectivamente.

**Tabela 6. 8** – Síntese dos resultados da análise gráfica dos modelos da Pista Sul (MVPLN)

Modelo	<i>Q-Q Plot</i> (2011-2014/2015-2018)	<i>Residual Q-Q Plot</i> (2011-2014/2015-2018)	<i>Residual autocorrelation</i> (2011-2014/2015-2018)
PN_500m	GD/GD	DI-IF/DI-IF	+Auto-NASV/Auto-B
PN_1km	GD/GD	DI-IF/DI-IF	+Auto-NASV/Auto-B
PN_1,5km	GD/GD	DI-IF/DI-IF	Auto-NASV/Auto-B
PN_2km	MD/GD	DM-IF/DM-IF	Auto-B/Auto-B
PN_2,5km	MD/MD	DM-IF/DM-IF	Auto-MB/Auto-MB
PN_3km	MD/MD	DM-IF/DM-IF	Auto-MB/Auto-MB
PN_3,5km	MD/MD	PD-IF/PD-IF	Auto-MB/Auto-MB
PN_4km	PD/PD	PD-IF/PD-IF	Auto-MB/Auto-MB
PN_4,5km	PD/PD	PD-/PD-IF	Auto-MB/Auto-MB
PN_5km	PD/PD	PD-IF/PD-IF	Auto-MB/Auto-MB

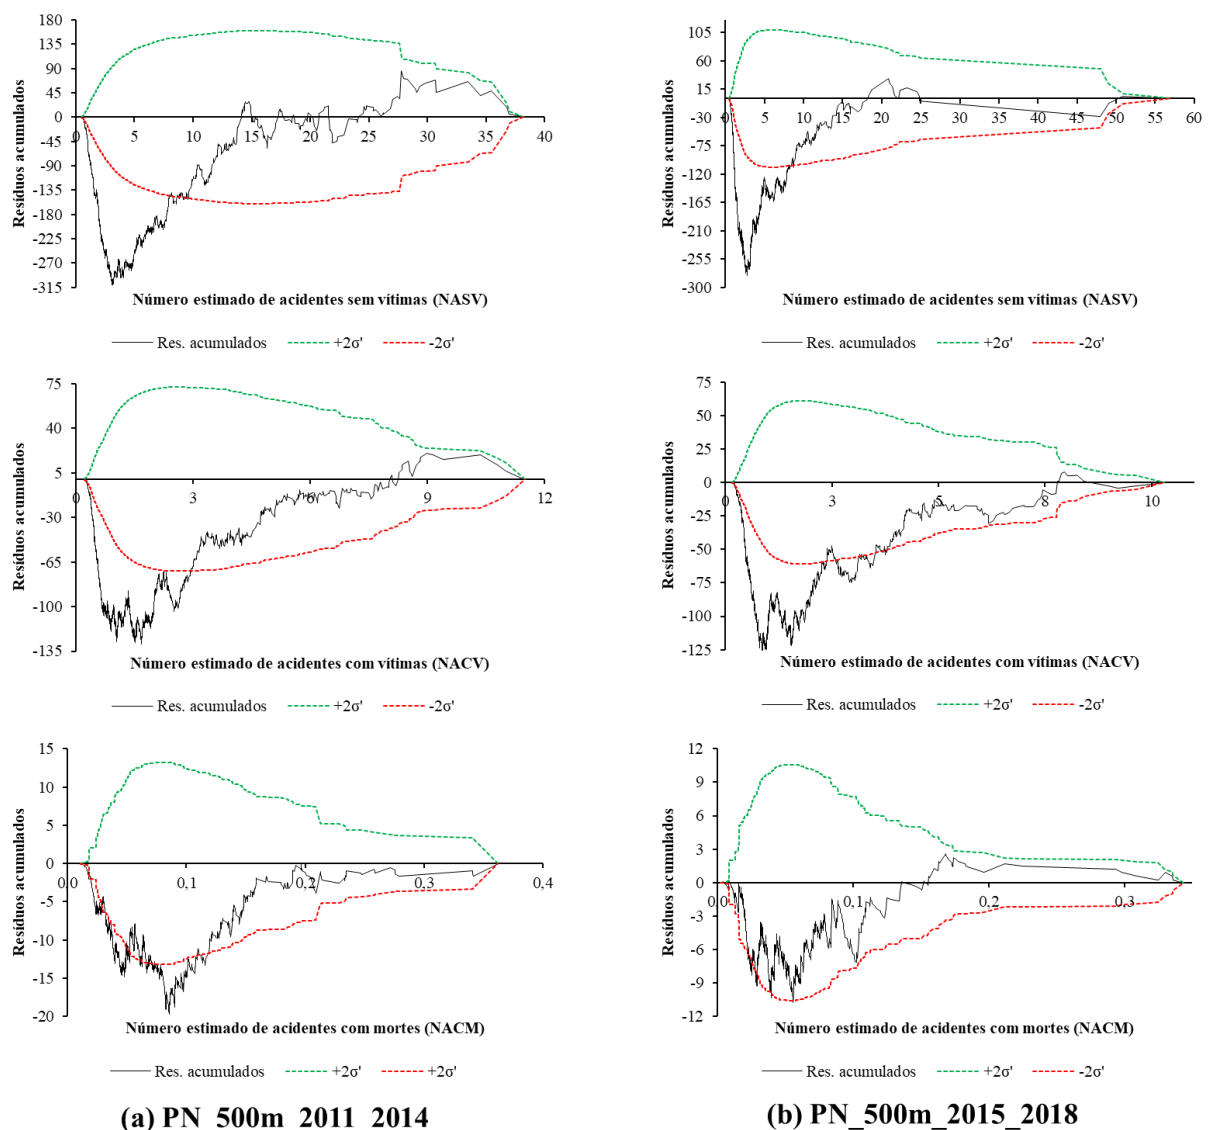
Legenda: GD: grandes desvios; MD: médios desvios; PD: pequenos desvios; DI-IF: desvios importantes no início e final da linha; DM-IF: desvios médios no início e final da linha; PD-IF: pequenos desvios no início e final da linha; +Auto-NASV: existência de elevada autocorrelação de resíduos para NASV; Auto-NASV: existência de autocorrelação de resíduos para NASV; Auto-B: autocorrelação baixa; Auto-MB: autocorrelação muito baixa ou inexistente.

Como ocorrido nos cenários anteriores, os segmentos mais extensos ajustam-se melhor e os resíduos se comportam razoavelmente dentro do esperado. Especialmente os segmentos 3,5 km, 4 km e 4,5 km têm os melhores ajustes, ocorrendo ligeiras diferenças de desempenho. Após análise dos resultados optou-se pela utilização do segmento de 4 km como o melhor modelo para a Pista Sul, tanto de 2011 a 2014 quanto de 2015 a 2018.

Para *NASV* e *NACV*, em ambos os períodos, têm-se bom ajuste no *Scatter Plot* e *Q-Q Plot*, com ocorrência de desvios médios. Quanto à análise de resíduos, especialmente de 2011-2014, o histograma não se apresenta totalmente consistente com a distribuição normal, mas o *Residual Q-Q Plot* revela boa adequação com desvios apenas nas extremidades da reta, o que deve decorrer da existência de pontos discrepantes. Os resíduos padronizados, estão dispersos em torno de zero e atendem razoavelmente aos limites de confiança dos gráficos *Residuals vs Simulated* e *Residual vs Order/Time*. Ainda assim, especialmente no período 2011-2014 são observados pontos com alto desvio, podendo-se considerar como *outliers*. Por fim, o *Residual Autocorrelation Plot* revelou a existência de muito baixa autocorrelação nos resíduos em todos os casos.

Conseqüentemente, os modelos adotados podem ser classificados como de desempenho de média magnitude, com desvios médios, convergência entre valores observados e previstos, proximidade da distribuição normal de resíduos, dispersão aceitável dos resíduos padronizados e muito baixa autocorrelação nos resíduos.

Como etapa final de avaliação do ajuste dos modelos, tem-se a análise dos *CURE Plot*. A Figura 6.9 apresenta os gráficos para os segmentos de 500 m da Pista Norte para os períodos de 2011-2014 e 2015-2018.

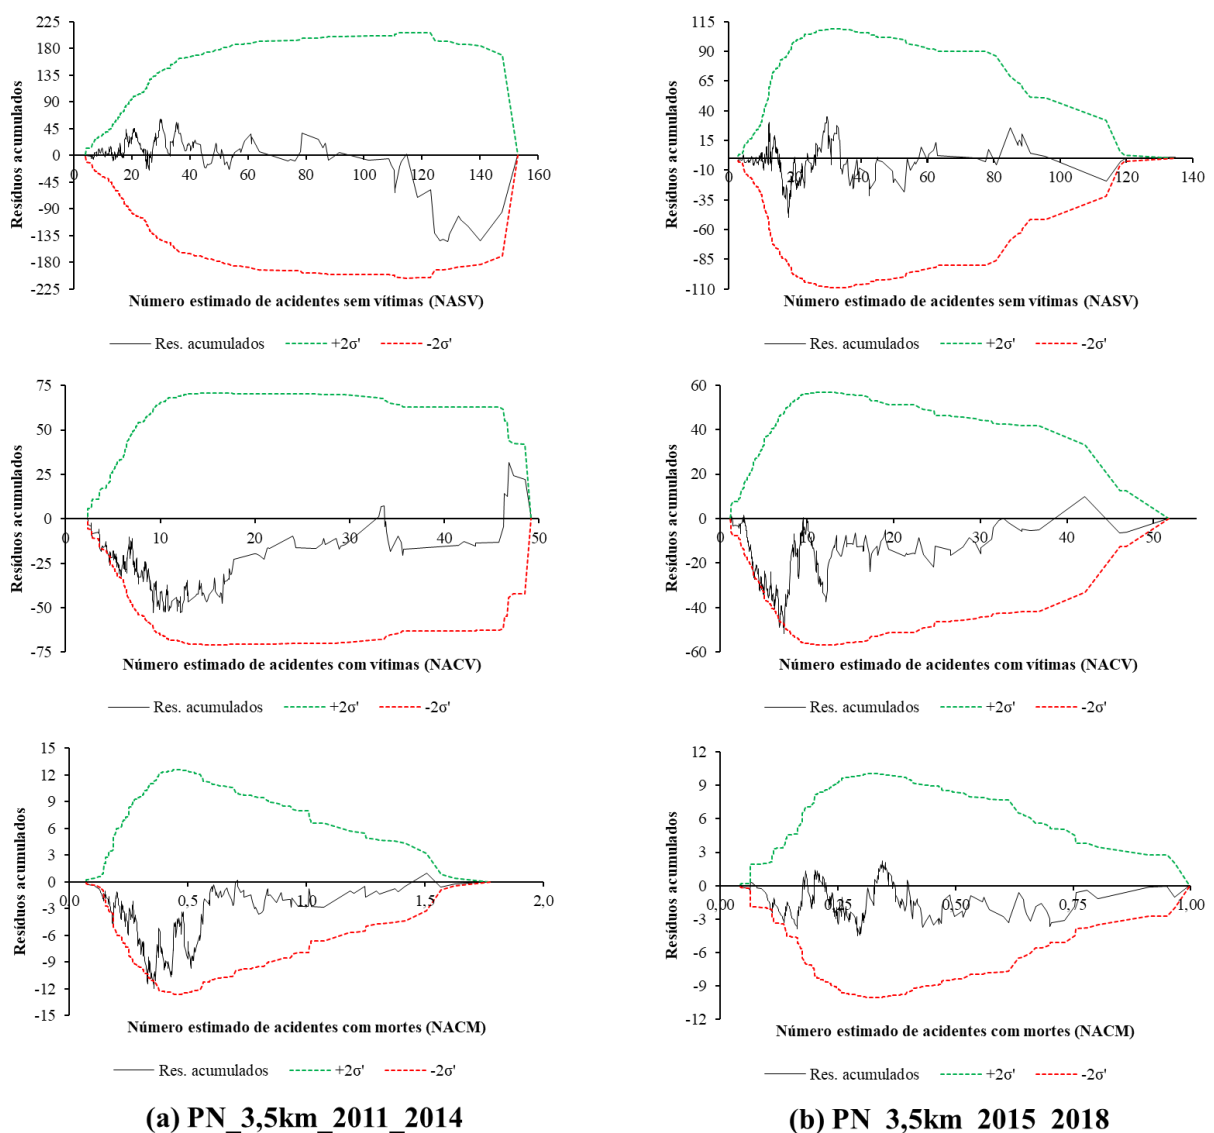


**Figura 6.9 - CURE Plot (MVPLN) – Pista Norte, 500 m**

Convergindo com as constatações advindas dos modelos de RNA, os segmentos mais curtos – especialmente de 500 m – são tidos como inadequados por apresentarem grandes picos de



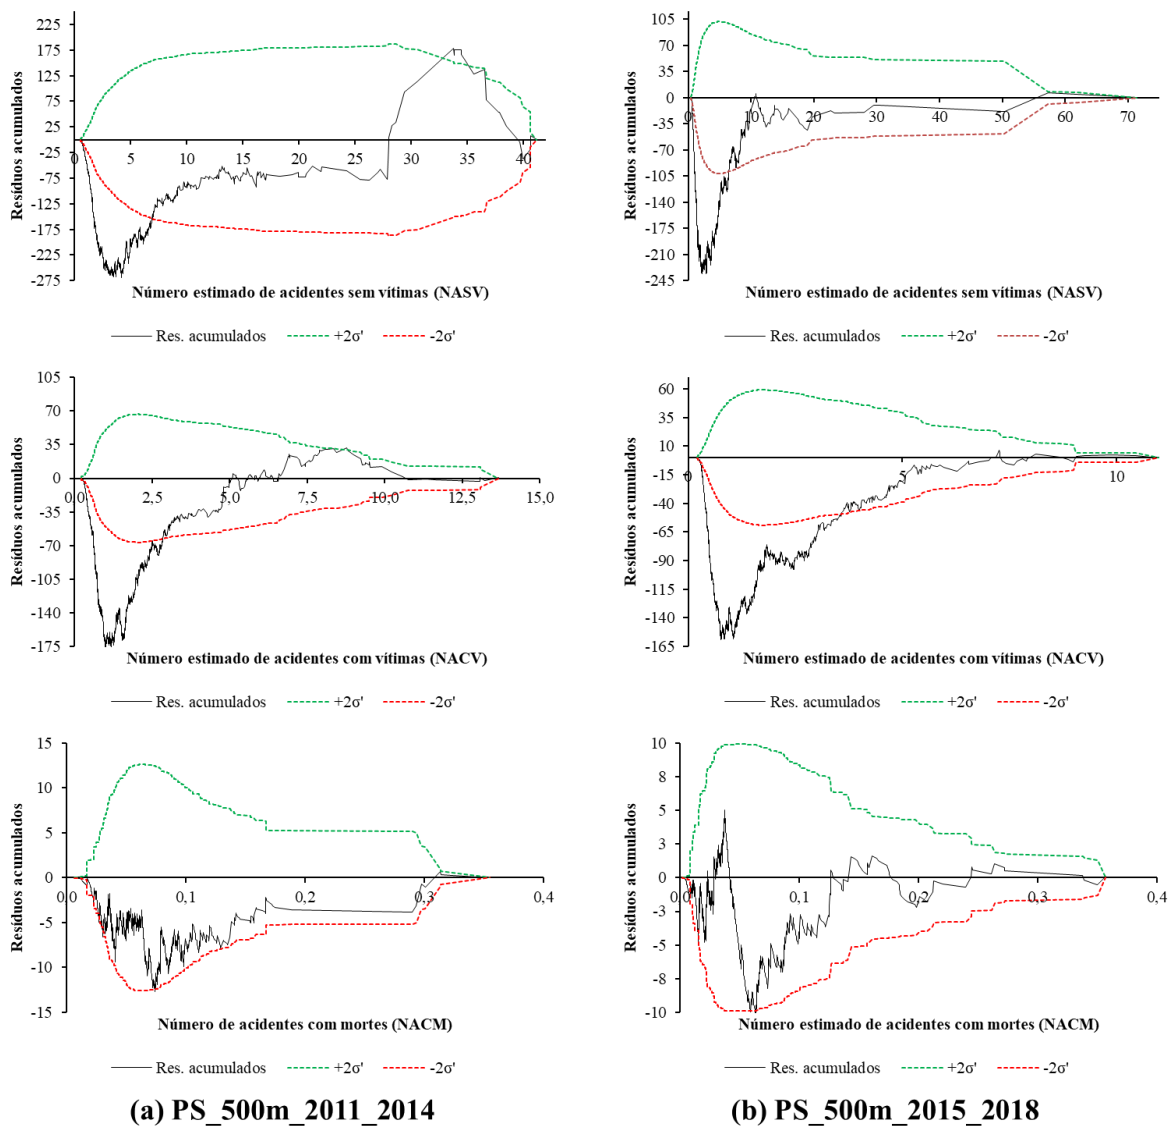
resíduos acumulados e terem a maior parte dos resíduos muito distantes das bandas limítrofes aceitáveis tanto para o número estimado de acidentes sem vítimas quanto para o número estimado de acidentes com vítimas. O comportamento verificado aponta para enviesamento significativo dos modelos e não aceitação destes. Nos segmentos mais extensos é nítida a melhoria da qualidade dos *CURE Plot*, embora tenha sido observado um padrão desviante, em menor ou maior grau, para todos os casos. Apesar dos segmentos de 4 km, 4,5 km e 5 km terem qualidade comparável, considerando as análises precedentes, fez-se a adoção do segmento de 3,5 km como de melhor ajuste, pelo que os respectivos gráficos de resíduos acumulados estão apresentados na Figura 6.10.



**Figura 6.10** – CURE Plot (MVPLN) – Pista Norte, 3,5 km

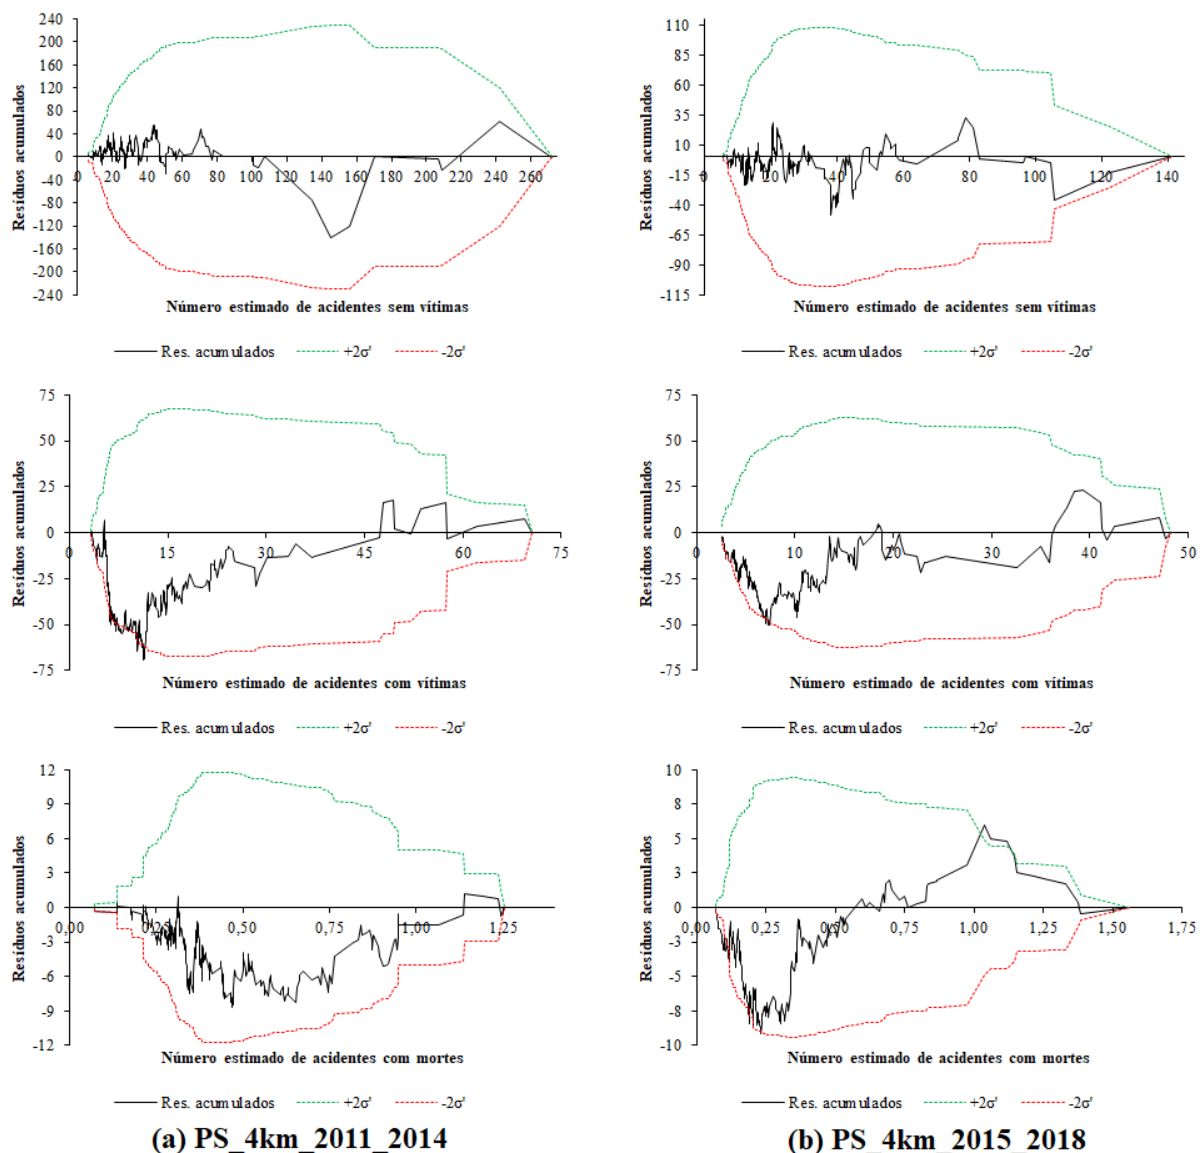
No caso dos acidentes sem vítimas, em ambos períodos de tempo, o *CURE Plot* foi adequado com resíduos variando, razoavelmente, em torno de zero e respeitando a envoltória  $\pm 2\sigma'$ . Para os acidentes com vítimas, especialmente no período 2015-2018, em raros pontos, especialmente em torno de 7,3, tem-se o desrespeito ao limite inferior  $-2\sigma'$ , não sendo indicativo para macular a qualidade do modelo. Ademais, a curva de resíduos acumulados terminou com valores próximos a zero, o que também é desejável.

Para a Pista Sul, sob a ótica de qualidade dos *CURE Plot*, nota-se enviesamento sistemático dos modelos de segmentos mais curtos. A Figura 6.11 apresenta os gráficos para os segmentos de 500 m para o período 2011-2014 e 2015-2018.



**Figura 6. 11 – CURE Plot (MVPLN) – Pista Sul, 500 m**

Em ambos os casos, especialmente para *NACV*, os resíduos acumulados estavam fora das bandas limítrofes em ampla faixa de valores. Além disso, a curva de resíduos acumulados assume valores muito elevados, especialmente no início do gráfico, observado pela queda acentuada e posterior crescimento, que corresponde a uma região de consistente superestimação. A melhoria da qualidade dos *CURE Plot* é percebida com o aumento da extensão do segmento, ainda que todos ultrapassem, mesmo que em raros pontos, os limites  $\pm 2\sigma'$ .



**Figura 6. 12** – CURE Plot (MVPLN) – Pista Sul, 4 km

Mediante análise de todos os cenários e das medidas de desempenho anteriores, fez-se a escolha do segmento de 4 km como melhor modelo para ambos períodos de tempo, tendo os resultados gráficos correspondentes apresentados na Figura 6.12. A linha de variação dos resíduos

acumulados oscila, razoavelmente, em torno de zero para *NASV* e *NACV*, com valores finais próximos de zero, como desejável. Nota-se, entretanto, a extrapolação do limite inferior de confiança para o patamar de 6 a 12 acidentes com vítimas. O restante do conjunto de dados não se desviou das bandas limítrofes, indicando que o viés identificado pode não ser significativo. De 2015 a 2018, também para *NACV*, apenas dois pontos excedem ligeiramente o limite inferior, o que não compromete a qualidade global do modelo.

Deste modo, a análise conjunta de erros e análise de resíduos, incluindo o *CURE Plot*, possibilitou escolher o segmento de 3,5 km como melhor modelo para Pista Norte e o segmento de 4 km como melhor modelo para Pista Sul, assim como constatado nos modelos resultantes do uso de RNA.

### **6.1.3. Previsão do número de acidentes com mortes**

Corroborando com a análise dos resultados, as previsões do Número de acidentes com mortes (*NACM*) são inadequadas em ambas as abordagens (RNA e MVPLN) e em todos os cenários. Embora algumas métricas de erro – nomeadamente MAD, MSE e RMSE – apresentem valores muito baixos, isso não se reflete em qualidade de ajuste. Tais medidas são absolutas e, por se tratar de um evento altamente estocástico com comportamento típico de ocorrência de zero acidente por segmento, o desvio entre o observado e o previsto tem baixa magnitude. Deste mesmo modo, as baixas estimativas em torno de zero também conduziram, na maioria dos casos, a *CURE Plot* aceitáveis para *NACM*. Ainda assim, destaca-se que os resultados auferidos são melhores que os verificados por outros autores, tais como Zeng *et al.* (2016b) em que o valor médio do MAD foi de 1,08 para redes neurais e 1,13 para modelo MVPLN em contraposição aos resultados deste trabalho de MAD = 0,345 e MAD = 0,40 para RNA e MVPLN, respectivamente.

As demais métricas relativas de erro, gráficos de qualidade de ajuste e comportamento de resíduos revelam a inadequação dos modelos para esse tipo de previsão. O ER, por exemplo, para segmentos de 500 m fica próximo da unidade, o que implica em dizer que o modelo desempenha tão bem quanto a simples média dos valores observados. Em outras palavras, tomar a média dos valores observados resulta numa previsão tão boa quanto a do modelo, o que é nada animador do ponto de vista da modelagem. Os altos valores de MSLE e baixos valores de  $R^2$  também reforçam a inadmissibilidade das previsões de *NACM*.

No que tange a qualidade de ajuste, o diagrama de dispersão e *Q-Q Plot* evidenciam o padrão de linhas verticais em 0, 1, 2 e 3 acidentes com mortes observados, estando os pontos totalmente fora da linha de 45°. De forma complementar, a análise de resíduos mostra a não normalidade na distribuição desses e ainda, dispersão enviesada dos resíduos padronizados, sem respeito às bandas limítrofes de confiança.

Tais constatações reiteram a necessidade de uma análise conjunta de diferentes métricas de erros e medidas de qualidade de ajuste para compreensão do comportamento mais completo do modelo. Se fossem utilizadas apenas as medidas de erro absoluto (MAD, MSE e RMSE, por exemplo) como é comum na literatura, poderia ser concluído, equivocadamente, que o modelo é apropriado para a previsão do número de acidentes fatais.

Embora se tenha partido da suposição de que, a partir dos dados disponíveis na gestão rodoviária brasileira, fosse possível modelar acidentes de trânsito segundo diferentes níveis de severidade, a ineficiência na previsão de acidentes com mortes não é surpreendente. Isso evidencia que os fatores viário-ambientais, operacionais e de pavimento não são eficientes para prever onde esse tipo de acidente deve acontecer. A ocorrência de um acidente que resulte numa vítima fatal extrapola as questões de engenharia e centram-se em aspectos humanos, veiculares e características específicas do acidente.

Conforme verificado na Revisão Sistemática de Literatura, a idade, sexo, condição de saúde dos ocupantes, uso de cinto de segurança e dispositivo de retenção para transporte de crianças, existência de dispositivos complementares de segurança veicular (*airbags*, freios ABS), condição de manutenção do veículo e outros fatores estão mais fortemente associados a severidade de um acidente, especialmente fatal, do que tão somente as características da via, tráfego e pavimento.

Fridstrom *et al.* (1995) afirma que a relação entre a exposição e acidentes (sem e com vítimas) é quase proporcional, mesmo que isso não seja observado para os acidentes com mortes. Segundo O'Donnell e Connor (1996), é indiscutível a relação entre os atributos dos ocupantes do veículo e o risco de lesões, devido a ocorrência de um acidente. E, de modo convergente, Morgan e Mannering (2011), Savolainen *et al.* (2011) e Koppel *et al.* (2018) também ressaltaram que a severidade do acidente, especialmente a fatalidade, está associada a uma

complexa interação entre os vários elementos relacionados ao fator humano e à física do acidente.


Ainda assim, buscando melhorar a previsão do número de mortes a partir dos modelos desenvolvidos, foram investigadas algumas alternativas:

- Modelo univariado – para fins de verificação, procedeu-se ao treinamento de uma RNA considerando como variável resposta apenas *NACM*;
- Rede neural secundária – aos resultados obtidos pela rede principal, foi associada uma nova rede para previsão de *NACM* como um problema de classificação (ocorrência ou não ocorrência de acidente com morte);
- *Random Forest* para classificação – semelhante à rede neural secundária, mas com uso de *Random Forest*, aos resultados obtidos da RNA fez-se a classificação do *NACM* (ocorrência ou não ocorrência);
- Rede neural com número total de acidentes – fez-se o treinamento de RNA considerando como variáveis de saída *NTA* (Número total de acidentes), *NASV* e *NACV* e, o número de acidentes fatais foi obtido da seguinte forma:  $NACM = NTA - NASV - NACV$ .

Mesmo com o empreendimento de grande esforço, nenhuma das abordagens resultou em melhoria de desempenho para a previsão do número de acidentes com mortes. O que, de outro lado, reforça a maior adequação dos modelos a uma abordagem multivariada e não univariada. Apesar disso, a utilização da pirâmide de Hydén (1987), conforme Figura 6.13, para obtenção indireta do número de acidentes com mortes pode ser útil. O autor teve como mote central a Análise de Conflitos de Tráfego (ACT) e não o estudo de acidentes ocorridos. Ainda assim, a pirâmide proposta, que reflete a interação entre usuários da via como uma sequência contínua de eventos cronologicamente dependentes que variam desde passagens sem distúrbios a acidentes, tem proveito na abordagem em tela.


Embora amplamente empregada no âmbito de acidente de trabalho, a proporção 1:10:30 entre os níveis de severidade de acidente enunciada por Bird e German (1966) parece se aproximar à realidade de nosso estudo. Isso implica dizer que para cada acidente fatal, ocorreram 10 acidentes com vítimas e 30 acidentes sem vítimas. Para além da proporção média entre o

número de acidentes dos diferentes níveis de severidade no conjunto geral de dados de acidentes, é necessário que isso também ocorra em termos de unidade de análise (segmento).




**Figura 6.13 – Pirâmide de Hydén**  
 Fonte: Hydén (1987) adaptado

Na Figura 6.14 está apresentada a proporção média entre o *NASV* e *NACV* para cada extensão de segmento em cada pista. Conforme resultados, a partir da extensão de 1,5 km, a proporção média se aproxima de 3, como referido por Bird e German (1966).



**Figura 6. 14–** Proporção entre acidentes sem vítimas e com vítimas nos dados observados

Além disso, de forma ilustrativa, multiplicou-se a proporção *NASV/NACV* ao número de acidentes com vítimas de cada observação do segmento de 3,5 km da Pista Norte (Figura 6.15), sendo possível notar a boa convergência entre os pontos.

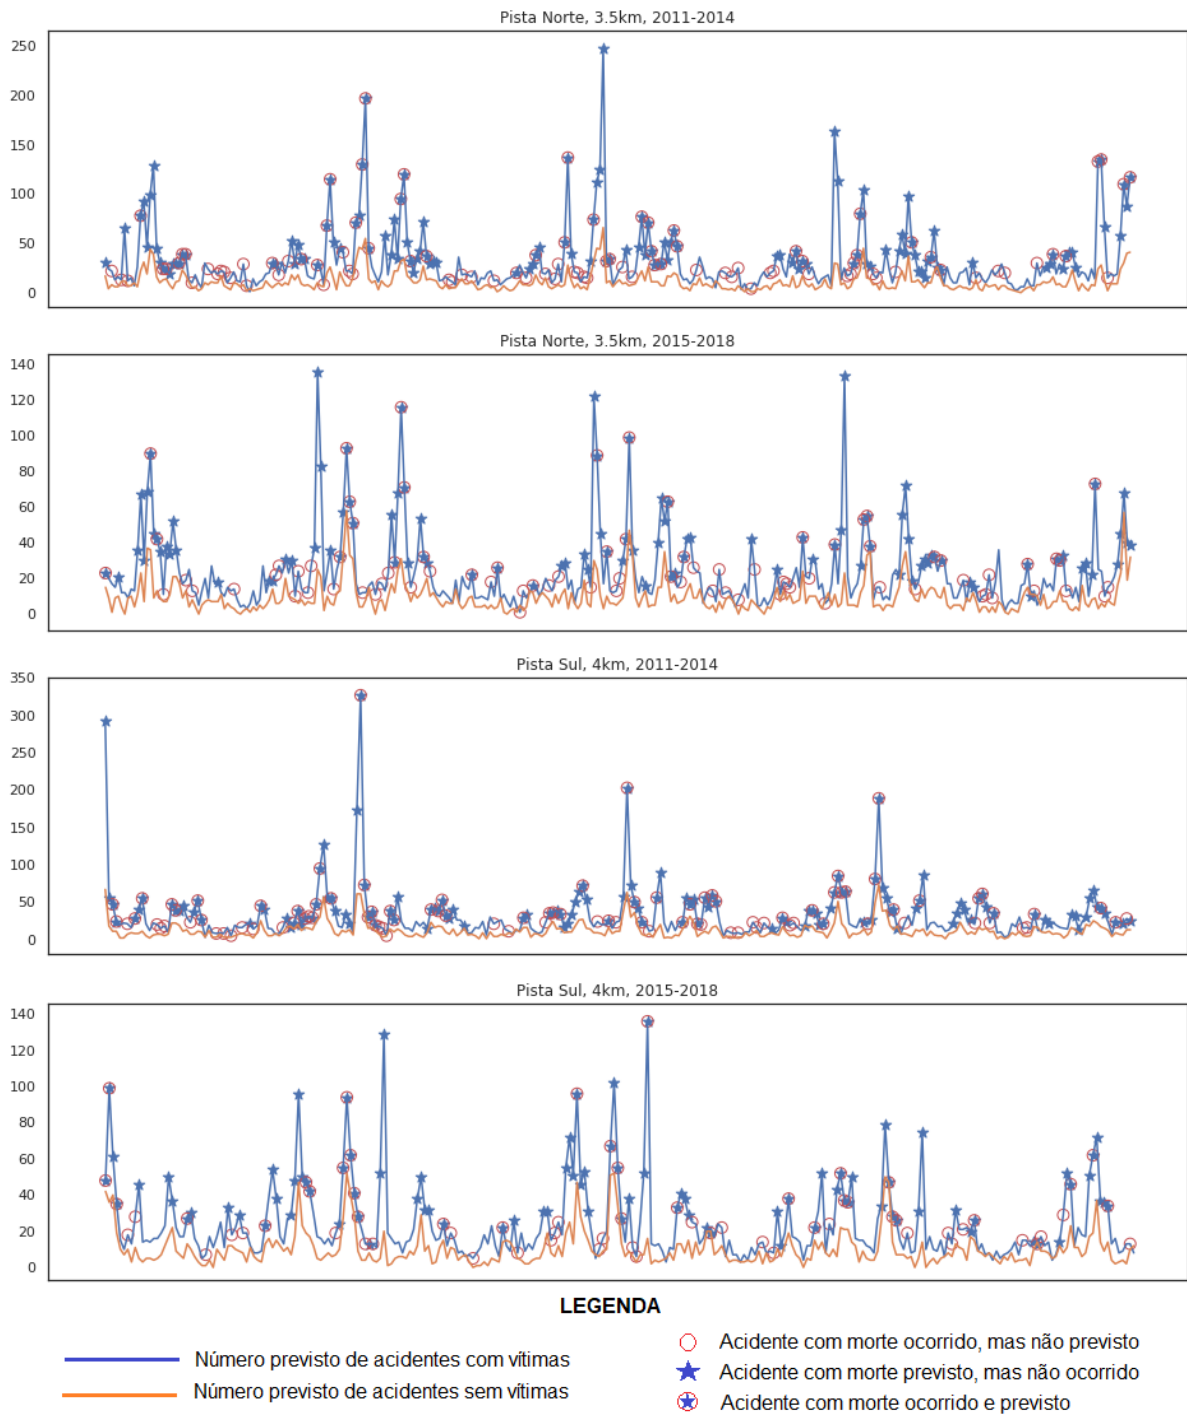


**Figura 6.15** – *NASV* e *NASV* ajustado pela proporção *NASV/NACV* para PN\_3,5km\_2011\_2014

Diante disso, considerando os bons resultados de previsão do número de acidentes sem vítimas (*NASV*) e com vítimas (*NACV*) e, valendo-se de uma adaptação da pirâmide de Hydén (1987) e da proporção de Bird e German (1966), os acidentes com mortes foram estimados de forma indireta, como um problema de classificação, em que ocorre pelo menos um acidente fatal no segmento, caso nele também tenha ocorrido, pelo menos, 30 acidentes sem vítimas ou 10 acidentes com vítimas ( $NASV/NACV = 3$ ).

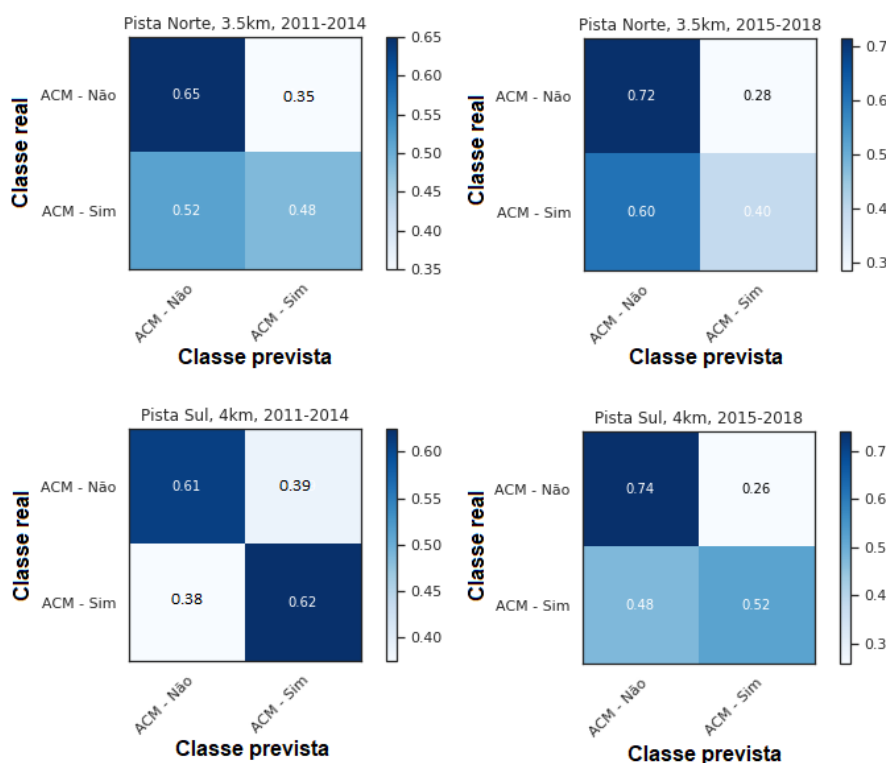
Na Figura 6.16 estão apresentados os resultados para os segmentos de 3,5 km da Pista Norte e de 4 km da Pista Sul, em ambos períodos de tempo, que são os melhores modelos advindos do emprego de RNA. Nos gráficos podem ser observados os valores previstos de *NASV* e *NACV*, representados pelas linhas de cores azul e laranja, respectivamente; também são observados círculos vermelhos, que representam acidentes com mortes ocorridos no segmento. Os círculos não preenchidos referem-se aos acidentes ocorridos, mas não previstos, as estrelas azuis referem-se aos acidentes previstos, mas não ocorridos e, os círculos preenchidos com as estrelas são os casos de acidentes observados que também foram previstos.





**Figura 6.16** – Estimativa indireta dos acidentes com mortes

Apesar da Figura 6.16 conceder uma ideia geral da qualidade dessa abordagem, é necessário avaliar as métricas de desempenho. Em razão do exposto, a Figura 6.17 demonstra a matriz de confusão para cada caso.



**Figura 6. 17**– Matriz de confusão da estimativa indireta dos acidentes com mortes (ACM)

Algumas conclusões são possíveis de extrair mediante análise da matriz. Em se tratando da extensão de 3,5 km para Pista Norte no período 2011-2014, em 52% das vezes que houve acidente com morte, a abordagem indicou não haver acidente nos respectivos segmentos. Esses valores são de 60%, 38% e 48% para os cenários PN\_3,5km\_2015\_2018, PS\_4km\_2011\_2014 e PS\_4km\_2015\_2018, respectivamente. O desempenho dos classificadores da Pista Sul é claramente superior ao dos da Pista Norte, no caso de haver acidente e a previsão acertar. No caso de não haver acidente, o classificador da Pista Norte para o período 2011-2014 é melhor do que o da Pista Sul, e para o período 2015-2018 é apenas ligeiramente inferior.

A acurácia média (medida que avalia a capacidade de o classificador acertar suas previsões) para a Pista Norte é de 0,57 e de 0,63 para a Pista Sul, desempenho mediano. Pelas Figuras 6.16 e 6.17 ainda se nota que o classificador, em média, aponta a ocorrência de acidente com mortes em 32% dos segmentos em que eles não ocorreram, configurando-se superestimação desse tipo de acidente. Esses resultados demonstram que, apesar de haver a proporcionalidade entre o *NASV* e *NACV*, a alta aleatoriedade de ocorrência de ACM não permite que a aplicação da proporção *NACM:NACV:NASV* conduza a bons resultados.

Em hipótese alguma busca-se substituir a modelagem específica para acidentes fatais, incorporando os fatores humanos e veiculares imprescindíveis para a explicação mais acurada do fenômeno. Ainda assim, vê-se o uso da proporção entre os níveis de severidade de acidentes como uma alternativa para uma grosseira estimativa de acidentes com mortes, a partir de boas previsões de acidentes sem vítimas e com vítimas, em casos que não se dispõe de outra possibilidade.

#### **6.1.4. Análise Comparativa dos Modelos**

Pelo apresentado nas Seções 6.1.1 e 6.1.2, as duas abordagens empregadas permitiram a obtenção de modelos que, conforme medidas de erro, qualidade de ajuste e análise de resíduos, apresentam validade replicativa. Ainda assim, é possível obter importantes considerações a partir dos resultados obtidos.

As comparações entre as medidas de desempenho estão apresentadas nas Tabelas 6.9 e 6.10, sendo que abaixo de cada medida segue um minigráfico de barras. O tamanho da barra é proporcional à diferença entre os valores, enquanto que as cores indicam redução (vermelha) ou aumento (azul) do valor da métrica do modelo de RNA em relação ao modelo MVPLN para o cenário equivalente.

É perceptível que, para quase todas as extensões de segmento, especialmente para *NASV*, os valores de erro obtidos por meio do emprego de RNA são sensivelmente inferiores aos valores provenientes dos modelos MVPLN. A título de exemplo, no segmento de extensão 2,5 km da Pista Sul no período 2011-2014, o Erro Relativo do modelo de RNA é 84% menor que o correspondente modelo MVPLN. Esse comportamento é notado tanto para Pista Norte quanto para Pista Sul, sendo mais evidente, em ambos os casos, no período de 2011 a 2014.

Para o *NACV* e *NACM*, nota-se a tendência de erros superiores dos modelos de RNA na maioria dos segmentos. No período 2011-2014, em ambas as pistas, a predominância das melhores métricas para *NACM* é claramente verificada para os modelos MVPLN. Para o *NACV*, especialmente na Pista Sul, constata-se que, a partir de 2,5 km, os modelos de RNA passam a apresentar melhor desempenho em termos de ER e  $R^2$  em ambos períodos de tempo. O que também é observado, com menor expressividade, para Pista Norte no período 2011-2014.

**Tabela 6.9 – Diferença percentual entre as medidas de desempenho dos modelos ajustados com uso de RNA e MVPLN, para Pista Norte**

Ext. do segmento	PN_2011_2014												PN_2015_2018														
	Diferença percentual entre modelos RNA e MVPLN - NASV				Diferença percentual entre modelos RNA e MVPLN - NACV				Diferença percentual entre modelos RNA e MVPLN - NACM				Diferença percentual entre modelos RNA e MVPLN - NASV				Diferença percentual entre modelos RNA e MVPLN - NACV				Diferença percentual entre modelos RNA e MVPLN - NACM						
	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE
500 m	47,46	-3,38	39,99	-17,20	26,34	-0,43	10,57	-20,35	1,85	0,03	-42,54	77,56	-3,25	32,93	-25,33	39,63	0,60	12,15	-31,05	1,24	1,15	-40,62					
1km	-9,42	-5,76	20,60	2,80	26,13	0,56	15,17	-10,88	4,39	0,24	-48,83	14,33	-7,32	5,78	-2,58	28,33	1,93	11,24	-12,23	0,19	-0,26	-8,35					
1,5 km	-47,37	-3,90	-4,93	10,84	17,70	-4,12	10,98	-4,93	6,54	-0,34	-51,05	-30,28	24,95	-4,96	4,16	14,80	1,74	12,75	-4,30	1,63	0,36	-22,98					
2 km	-65,30	25,46	-11,34	11,98	-0,20	2,92	10,13	-0,01	8,16	-0,17	-58,56	-41,98	-17,57	-18,49	5,26	19,07	4,58	14,44	-4,36	2,47	-0,90	-24,51					
2,5 km	-76,31	18,43	-20,99	12,00	-0,89	13,31	6,03	0,09	12,12	2,75	-67,85	-37,93	-27,30	-33,37	3,71	11,47	-14,82	-2,13	-2,28	0,69	-0,89	-7,02					
3 km	-63,95	-13,20	-23,40	8,62	-2,34	-56,10	1,30	0,29	5,43	0,99	-32,89	-46,69	-10,38	-28,07	4,20	5,56	12,84	16,65	-0,95	0,53	-2,21	-4,37					
3,5 km	-69,73	-34,47	-25,27	9,40	-0,43	24,19	11,96	-0,01	14,08	-0,04	-59,12	-63,14	-21,25	-42,58	5,11	14,40	-17,49	10,02	-2,07	4,40	-0,28	-35,17					
4 km	-71,21	15,56	-16,93	8,42	17,52	31,77	19,70	-2,29	10,00	0,01	-53,84	-45,86	-33,47	-34,91	3,76	9,41	24,23	13,89	-1,12	9,86	2,44	-51,72					
4,5 km	-68,83	-12,12	-15,75	6,98	-2,87	6,11	5,05	0,36	11,72	-0,93	-53,43	-54,69	-24,66	-30,27	3,81	31,13	25,56	26,13	-3,52	6,08	2,29	-50,75					
5 km	-73,16	-15,54	-9,02	8,23	0,59	33,07	11,92	-0,13	12,50	1,58	-49,54	-18,99	27,30	3,42	1,34	21,32	28,79	11,86	-2,45	7,55	0,68	-63,71					

**Tabela 6.10 - Diferença percentual entre as medidas de desempenho dos modelos ajustados com uso de RNA e MVPLN, para Pista Sul**

Ext. do segmento	PS_2011_2014												PS_2015_2018														
	Diferença percentual entre modelos RNA e MVPLN - NASV				Diferença percentual entre modelos RNA e MVPLN - NACV				Diferença percentual entre modelos RNA e MVPLN - NACM				Diferença percentual entre modelos RNA e MVPLN - NASV				Diferença percentual entre modelos RNA e MVPLN - NACV				Diferença percentual entre modelos RNA e MVPLN - NACM						
	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE
500 m	14,97	-3,96	35,14	-8,88	34,80	-2,34	16,30	-23,37	1,31	-0,83	-45,12	58,25	0,45	31,10	-16,58	38,51	0,22	13,44	-28,64	1,62	1,75	-37,95					
1km	-41,29	-1,17	20,76	20,84	30,65	-0,52	11,40	-11,91	3,68	1,01	-51,82	10,30	1,24	8,11	-2,17	38,61	2,40	11,96	-16,64	0,56	0,10	-9,06					
1,5 km	-62,32	0,72	-2,62	17,71	38,73	-1,51	16,18	-9,92	5,44	0,14	-66,65	-15,04	-2,25	-3,00	2,33	34,90	-4,07	9,65	-10,78	5,72	0,03	-54,35					
2 km	-73,97	14,75	-7,20	21,57	6,11	-1,22	9,00	-1,30	1,88	-0,88	-21,68	-41,49	17,37	-17,66	5,79	11,81	-2,74	8,45	-3,05	1,34	1,05	-9,82					
2,5 km	-84,35	20,04	-13,95	21,92	-22,34	-0,88	6,77	3,89	3,43	0,05	-35,15	-41,84	28,79	-20,09	5,61	-5,81	17,42	3,79	1,33	1,59	0,72	-7,87					
3 km	-77,08	-21,16	-22,31	15,53	-20,18	7,56	-3,03	2,98	7,47	2,08	-43,97	-57,28	-26,51	-38,03	6,01	2,23	6,48	11,05	-0,43	12,98	-0,23	-65,19					
3,5 km	-80,36	-3,33	-15,27	14,18	-10,24	25,19	5,62	1,35	12,11	1,88	-63,05	-46,97	-30,73	-39,79	4,42	-19,48	5,73	13,35	3,21	6,08	1,60	-29,87					
4 km	-81,29	-34,68	-26,16	12,95	-25,28	0,51	7,63	2,95	2,62	1,63	-16,92	-68,10	-41,15	-46,57	6,11	-27,73	0,61	-6,62	4,47	10,70	2,14	-39,67					
4,5 km	-82,12	-22,22	-25,28	14,81	-17,03	-85,80	15,00	2,05	12,74	1,58	-60,61	-53,22	-20,11	-34,99	4,78	-24,03	26,82	0,18	3,60	8,89	4,65	-32,19					
5 km	-80,85	0,52	-11,93	17,28	-2,26	19,43	16,55	0,28	14,51	-2,82	-57,29	-23,61	-13,58	-20,61	1,76	39,54	38,24	24,83	-5,25	12,32	3,92	-41,14					

Em termos de valores médios, considerando todos as extensões de segmento, o comportamento é convergente. Para a Pista Norte, nos dois períodos, os menores valores médios de erro e maiores valores médios de  $R^2$  de *NASV* são verificados nos modelos de RNA. Já para *NACV* e *NACM*, os melhores valores médios ocorrem basicamente nos modelos MVPLN. Na Pista Sul ocorre de forma similar, no entanto, para *NACV*, especificamente para MSLE os valores médios são menores nos modelos de RNA.

Em termos dos modelos selecionados, conforme se observa na Tabela 6.11, para a Pista Norte, nos dois períodos de tempo analisado, o melhor ajuste para *NASV* é indiscutivelmente dos modelos de RNA, enquanto que, mesmo que de forma ligeira, as métricas de *NACV* e *NACM* são melhores nos modelos MVPLN. A linha de tendência constante na tabela permite identificar o ponto verde como sendo o melhor valor e o vermelho como o pior; sempre o primeiro ponto corresponde ao modelo de RNA e o segundo, ao modelo MVPLN.

**Tabela 6. 11**– Comparação das medidas de desempenhos dos modelos de RNA e MVPLN selecionados para Pista Norte

Modelo	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	MdAPE	R <sup>2</sup>	ER	MSLE	R <sup>2</sup>	
	PN_2011_2014_NASV				PN_2011_2014_NACV				PN_2011_2014_NACM			
3,5 km - RNA	0,036	0,050	11,714	0,964	0,131	2,536	22,181	0,869	0,923	206,516	0,079	
3,5 km - MVPLN	0,119	0,076	15,675	0,881	0,131	2,042	19,812	0,870	0,809	206,595	0,194	
Tendência												
	PN_2015_2018_NASV				PN_2015_2018_NACV				PN_2015_2018_NACM			
3,5 km - RNA	0,028	0,061	9,574	0,972	0,140	6,991	24,410	0,860	0,925	217,710	0,075	
3,5 km - MVPLN	0,075	0,078	16,673	0,925	0,123	8,472	22,188	0,878	0,886	218,327	0,115	
Tendência												
	PS_2011_2014_NASV				PS_2011_2014_NACV				PS_2011_2014_NACM			
4km - RNA	0,026	0,051	12,008	0,974	0,079	0,167	22,133	0,921	0,872	204,423	0,129	
4km - MVPLN	0,137	0,078	16,263	0,863	0,106	0,166	20,565	0,894	0,850	201,150	0,155	
Tendência												
	PS_2015_2018_NASV				PS_2015_2018_NACV				PS_2015_2018_NACM			
4km - RNA	0,026	0,044	8,869	0,974	0,101	5,713	20,126	0,899	0,883	221,452	0,122	
4km - MVPLN	0,082	0,075	16,599	0,918	0,140	5,679	21,552	0,860	0,798	216,818	0,202	
Tendência												

Legenda: Ponto verde – melhor valor; Ponto vermelho – pior valor; Ponto à esquerda – RNA; Ponto à direita – MVPLN.

Na Pista Sul, como é visto na Tabela 6.11, de igual modo à Pista Norte, os modelos de RNA é que apresentam os melhores resultados em termos de *NASV*. Além disso, para essa pista tem-se também a predominância dos melhores resultados para *NACV* nos modelos de RNA. Quanto ao *NACM*, com pequenas diferenças, os modelos MVPLN alcançaram performance melhor.

Em termos de qualidade de ajuste e análise de resíduos, os resultados são comparáveis, notando-se a clara tendência de melhoria de desempenho à medida que os segmentos se tornam mais extensos até o segmento de extensão “ideal”. E, de forma mais específica, algumas constatações são feitas. Para a Pista Norte no período de 2011 a 2014, são constatados maiores valores de ACF (*autocorrelation function*) para os modelos MVPLN, indicando maior propensão destes à dependência dos resíduos. Os desvios nos gráficos de dispersão e *Q-Q Plot* dos modelos MVPLN são ligeiramente superiores aos observados nos modelos de RNA. Além disso, os modelos estatísticos são menos eficientes para previsão dos valores mais altos de *NASV* e *NACV*. Quanto aos resíduos padronizados, nos modelos MVPLN são notados valores discrepantes em quase todas as extensões de segmento. E ainda, no geral, as distribuições de resíduos dos modelos de RNA são mais consistentes com a distribuição normal. No período 2015-2018, ainda com referência à Pista Norte, nota-se comportamento similar, reforçando-se os maiores valores de autocorrelação nos resíduos para modelos MVPLN, existência de valores discrepantes de resíduos padronizados – embora em menor magnitude – e maior adequação dos resíduos dos modelos de RNA à distribuição gaussiana. Em relação aos desvios, no entanto, a diferença nos gráficos de dispersão e *Q-Q Plot* são menos notáveis.

Para a Pista Sul, no período 2011-2014, as constatações são convergentes. Especialmente nos segmentos mais curtos (até 2,5 km), a autocorrelação nos resíduos são notavelmente superiores nos modelos MVPLN do que nos modelos de RNA. Percebe-se valores discrepantes de resíduos padronizados e desvios ligeiramente superiores nos gráficos de dispersão e *Q-Q Plot* para os modelos MVPLN. Esses modelos também não apresentam boa capacidade de previsão dos valores mais altos de *NASV* e *NACV* e têm resíduos menos consistentes com a distribuição normal. No período posterior para Pista Sul tem-se desempenho semelhante, sendo possível identificar bastante similaridade dos desvios dos gráficos de dispersão e *Q-Q Plot* dos modelos MVPLN e modelos de RNA, apesar de esses últimos ainda terem melhor ajuste.

Diante disso, na conjuntura geral, é possível afirmar que os gráficos produzidos a partir dos resultados de RNA remetem a melhor qualidade desses modelos, mesmo que com pequena variação. Por outro lado, tratando-se especificamente dos modelos escolhidos, é mais nítida a superioridade dos modelos de RNA frente aos MVPLN.

Adicionalmente, os *CURE Plot* também foram comparados. Os modelos para Pista Norte nos dois períodos de tempo tiveram desempenho similar em ambas abordagens. Em geral, para o

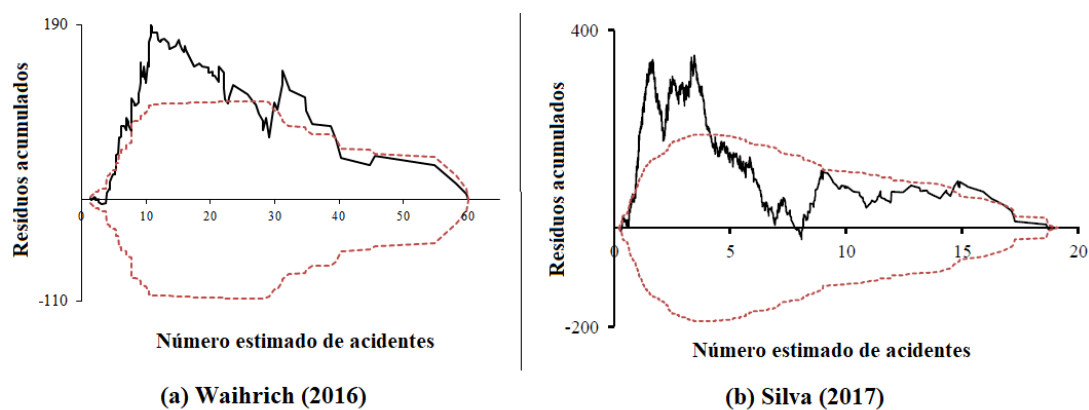
mesmo cenário (pista, extensão e período de tempo) observou-se a ocorrência de desvios nos gráficos tanto na abordagem de RNA como de MVPLN. Especialmente para *NASV* a magnitude dos resíduos acumulados foi maior no período 2011-2014, como de se esperar devido à diminuição do número de registro de acidentes a partir de 2015. Entretanto, quando comparadas as abordagens, a amplitude dos resíduos acumulados é sensivelmente maior para os modelos MVPLN em qualquer período de tempo. Na Pista Sul ocorre de modo semelhante, notando-se, em geral, a ocorrência de padrão desviante do *CURE Plot*, para um cenário específico, tanto para os resultados obtidos por RNA quanto por MVPLN. Como na outra pista, os valores de resíduos acumulados no período 2011-2014 são superiores ao do período 2015-2018, e os dos modelos MVPLN consideravelmente superiores aos dos modelos de RNA, independente do período.

Em nenhum dos casos, a superioridade de desempenho em termos do período de tempo foi claramente observada, performando de forma semelhante nos dois períodos, em ambas as técnicas empregadas. Nota-se ainda que, especialmente para *NASV*, o comportamento da curva de resíduos acumulados dos modelos MVPLN é mais próximo do desejável que o dos modelos de RNA, embora estes últimos também sejam aceitáveis. Quando se trata do *NACV* esse comportamento já não é notado e, no caso dos modelos MVPLN, a inferioridade de adequação é patente.

Outra constatação geral é de que, sempre que ocorre, a extrapolação da curva de resíduos acumulados dos modelos MVPLN se dá no limite inferior, ao passo que, nos modelos de RNA ora ocorre junto ao limite inferior, ora junto ao limite superior. Esse comportamento verificado em todos os modelos MVPLN com padrão desviante no *CURE Plot* pode indicar um padrão sistemático de superestimação de valores. Ainda quanto à extrapolação das bandas limítrofes do gráfico, observa-se que tipicamente ocorrem no final do gráfico (valores mais altos de número estimado de acidentes) nos modelos de RNA e, essencialmente no início do gráfico (valores iniciais de número estimado de acidentes) nos modelos MVPLN. O ajuste global do modelo RNA é razoável para maior parte dos valores de acidentes, embora note-se tendência de subestimação e superestimação em alguns casos. Doutro lado, os modelos MVPLN têm dificuldade de adequação à faixa de valores iniciais de acidentes, mas são eficientes no ajuste dos valores restantes.

Agora tratando especificamente dos modelos selecionados, embora todos tenham comportamento aceitável, como foi discutido nas seções anteriores, os modelos de MVPLN apresentam, comparativamente, *CURE Plot* mais desejáveis para *NASV* na Pista Norte 2011-2014 e para *NACM* no período 2015-2018, enquanto que nessa pista no período 2011-2014 os gráficos com características mais desejáveis de *NACV* e *NACM* ocorreram nos modelos de RNA, assim como para *NASV* e *NACV* no período posterior. Na Pista Sul, em ambos períodos de tempo, os modelos MVPLN retornaram os gráficos de comportamento mais desejável para *NASV*, à medida que as melhores performances para *NACV* e *NACM* ocorreram nos modelos de RNA. De todo modo, é importante referir que em todos os casos, independente do comportamento da curva, os modelos MVPLN acumularam mais resíduos.

Ante a comparação dos modelos, é oportuno resgatar os resultados de dois trabalhos recentes desenvolvidos no contexto brasileiro também objetivando a previsão de acidentes em rodovias, mas com o emprego do método do *Highway Safety Manual* (HSM). Waihrich (2016) procedeu à calibração de modelos para trechos de rodovias de pista dupla inseridas no Distrito Federal, Goiás e Minas Gerais. Já Silva (2017), ajustou modelos para trechos de rodovias de pista simples nos estados de São Paulo, Minas Gerais e Paraná. Os dois trabalhos adotaram como estratégia de segmentação da rodovia a divisão dos trechos analisados em segmentos homogêneos, variando a extensão dos segmentos de 0,15 a 6,2 km (média de 1,38 km) para o primeiro trabalho (WAIHRICH, 2016) e de 0,10 a 6,14 km (média de 0,70 km) para o segundo (SILVA, 2017). Ambas as abordagens objetivaram a previsão do número total de acidentes, e os *CURE Plot* resultantes da aplicação do HSM para todos os segmentos analisados encontram-se na Figura 6.18.



**Figura 6. 18** - *CURE Plot* resultantes de modelos de previsão de acidentes no contexto brasileiro empregando-se o método do HSM  
 Fonte: Waihrich (2016) e Silva (2017) adaptados



Conforme vê-se na imagem, nos dois casos tem-se no patamar de valores iniciais tendência de subestimação do número de acidentes. Embora não se trate de abordagem multivariada de previsão de acidentes, como a desta tese, tais resultados reforçam a adequação de desempenho dos modelos aqui desenvolvidos, tanto com uso de RNA como com o emprego de MVPLN.

De volta ao presente estudo, diante da análise realizada, nota-se a similitude de desempenho dos modelos MVPLN e de RNA, o que já bastaria para confirmar o potencial de utilização dessa técnica de AM para a modelagem de acidentes. Contudo, ao considerar conjuntamente as medidas de erro, qualidade de ajuste e análise de resíduos – incluindo *CURE Plot* –, verifica-se maior adequação das redes neurais como abordagem para previsão de acidentes segundo diferentes níveis de severidade. Vale a ressalva de que, de todo modo, em nenhuma abordagem a previsão do número de acidentes com mortes foi razoável, pelos motivos já elencados anteriormente.

A inexistência de autocorrelação nos resíduos e consequente independência dos erros nos modelos selecionados, indica que os dados foram adequadamente abordados com a técnica empregada. A não descoberta de padrões ou vieses nos resíduos padronizados em termos da ordem espacial também reforçam o tratamento adequado, mesmo sabendo que as observações são medidas repetidas.

O desempenho similar da Pista Norte e Pista Sul nos dois períodos de tempo sinalizam que, embora tenha havido mudança na forma de registro dos acidentes, isso não predomina sobre a influência da extensão do segmento. Doutra forma, esses resultados similares, mesmo diante da diferença no *modus operandi* do registro de acidentes, convergem para o mesmo tipo de influência da extensão do segmento.

A convergência da extensão de 3,5 km como sendo a que resulta nos modelos de melhor performance para Pista Norte, independente do período temporal e da técnica empregada, e da extensão de 4 km para a Pista Sul, revelam que tais extensões acomodam melhor a informação de cada variável e otimizam o processo de modelagem. Essa constatação converge com a obtida por Green (2018) que, também em rodovia de pista dupla, concluiu que a extensão ideal para modelagem era de 2 milhas (3,2 km). Aliás, em verdade, os resultados do presente trabalho sugerem que, a partir de 3,5 km, a extensão do segmento deixa de ser preponderante para a qualidade da previsão dos acidentes.

De forma complementar, como já relatado, para o mesmo cenário (pista, extensão de segmento e período de tempo), o comportamento resultante do emprego de RNA e de MVPLN é similar, o que corrobora para a suposição de que os achados do estudo são mais associados aos dados e fenômeno do que a técnica empregada.

## 6.2. VALIDAÇÃO PREDITIVA

A etapa de validação preditiva implica, conforme Oh *et al.* (2003), Lord e Park (2008) e Couto e Ferreira (2011), na qualidade de ajuste do modelo para dados independentes. Para tanto, a rede treinada de cada um dos modelos selecionados foi apresentada a um conjunto de dados de validação (neste caso uma amostra de 20% do conjunto total de dados), avaliando-se métricas de erro (ER, MSLE, MdAPE),  $R^2$ , comparação de estatísticas descritivas, comparação direta de valores observados e previstos, e análise gráfica de resíduos.

Infortunadamente, como já referido no Capítulo 5, essa validação não foi possível de ser conduzida para os modelos MVPLN. Os efeitos aleatórios que capturam a correlação existente entre os níveis de severidade conduzem ao ajuste razoável do modelo (validade replicativa), no entanto, é parte necessária do modelo e não permite a utilização direta dos coeficientes  $\beta_s$  para previsão do número de acidentes em outro conjunto de dados.

Na Tabela 6.12 estão apresentadas as medidas de desempenho de validação dos modelos selecionados. Com raras exceções, todas as medidas tiveram piora na execução de validação. Percentualmente, a diferença entre o resultado de treinamento e teste para algumas métricas, especialmente ER, é alta. Isso porque no treinamento os erros desse tipo tiveram valores muito próximos a zero para NASV, enquanto que na validação, ainda que com valores plenamente admissíveis, o patamar de valores foi superior.

Outro aspecto a destacar é que tanto para Pista Norte quanto para Pista Sul, os melhores resultados e menores diferenças entre treinamento e validação ocorreram no período de 2011 a 2014. Embora seja um comportamento verificado para todas as variáveis resposta, é mais patente para NASV. Especialmente para as medidas relativas (ER e MdAPE) e  $R^2$ , essa diferença de desempenho entre os períodos é melhor delineada. Especificamente em relação ao coeficiente de determinação, a diferença entre o treinamento e teste em 2011-2014 para NASV

e *NACV* foi de -0,44% e 2,82% para Pista Norte e, -2,8% e -8,3% para Pista Sul. Para o período de 2015 a 2018 a diferença média é de -21%.

**Tabela 6. 12** – Medidas de desempenho de validação dos modelos selecionados

Modelo	<i>NASV</i>			
	ER	MSLE	MdAPE	R <sup>2</sup>
PN_3,5km_2011_2014	0,052	0,189	20,631	0,953
PN_3,5km_2015_2018	0,257	0,142	22,823	0,762
PS_4km_2011_2014	0,079	0,132	17,952	0,947
PS_4km_2015_2018	0,222	0,158	29,131	0,680
Modelo	<i>NACV</i>			
	ER	MSLE	MdAPE	R <sup>2</sup>
PN_3,5km_2011_2014	0,117	0,121	22,700	0,891
PN_3,5km_2015_2018	0,191	14,165	24,614	0,813
PS_4km_2011_2014	0,159	0,229	23,808	0,844
PS_4km_2015_2018	0,349	6,143	38,187	0,657
Modelo	<i>NACM</i>			
	ER	MSLE	MdAPE	R <sup>2</sup>
PN_3,5km_2011_2014	1,080	227,881	-	0,026
PN_3,5km_2015_2018	1,007	233,925	-	0,029
PS_4km_2011_2014	1,025	171,395	-	0,036
PS_4km_2015_2018	0,834	194,167	-	0,001

Para os acidentes com mortes, os indicadores de ER e R<sup>2</sup>, que já não eram aceitáveis nos modelos inicialmente ajustados, experimentaram leves quedas de performance na validação. Por fim, numa análise global, o modelo PN\_3,5km\_2011\_2014 é que teve o comportamento de validação mais condizente com o de treinamento.

De acordo com Bennett *et al.* (2013), a comparação entre as estatísticas dos conjuntos de dados observados e previstos, especialmente mínimo, máximo, média e desvio padrão, pode ser útil na análise da validação preditiva. Tendo isso em conta, apresenta-se na Tabela 6.13 o resumo das estatísticas de cada modelo. Os valores negritos são relativos aos dados previstos do conjunto de dados de validação e os valores entre parênteses referem-se às métricas dos dados observados nesse conjunto.

Nos modelos da Pista Norte, as estatísticas dos dados observados se aproximam dos dados previstos para *NASV* e *NACV*, especialmente em termos de média e desvio padrão. Para o caso da Pista Sul, os valores mínimos previstos de *NASV* e *NACV* são sensivelmente superiores aos valores mínimos observados, ainda assim, as magnitudes de média e desvio padrão entre os dois conjuntos de dados são similares. Assim, de forma geral, em todos os modelos, mas

especialmente nos dois da Pista Norte, nota-se à similaridade das estatísticas dos dados previstos e observados, como é desejado.



**Tabela 6.13** – Estatísticas descritivas dos dados previstos e observados dos modelos selecionados

	PN_3,5km_2011_2014			PN_3,5km_2015_2018		
	<i>NASV</i>	<i>NACV</i>	<i>NACM</i>	<i>NASV</i>	<i>NACV</i>	<i>NACM</i>
Mínimo	<b>1,40</b> (1,0)	<b>1,86</b> (1,0)	<b>0,028</b> (0,0)	<b>3,15</b> (3,0)	<b>0,70</b> (0,0)	<b>0,06</b> (0,0)
Máximo	<b>168,26</b> (197)	<b>56,16</b> (55,0)	<b>1,64</b> (3,0)	<b>89,03</b> (68,0)	<b>30,23</b> (35,0)	<b>0,67</b> (2,0)
Média	<b>28,72</b> (29,43)	<b>10,30</b> (11,24)	<b>0,43</b> (0,35)	<b>22,47</b> (21,56)	<b>8,74</b> (8,57)	<b>0,29</b> (0,22)
Desvio padrão	<b>28,11</b> (30,62)	<b>9,06</b> (10,55)	<b>0,22</b> (0,70)	<b>15,42</b> (14,24)	<b>5,38</b> (6,37)	<b>0,13</b> (0,47)
	PS_4km_2011_2014			PS_4km_2015_2018		
	<i>NASV</i>	<i>NACV</i>	<i>NACM</i>	<i>NASV</i>	<i>NACV</i>	<i>NACM</i>
Mínimo	<b>6,94</b> (3,0)	<b>2,60</b> (1,0)	<b>0,0</b> (0,0)	<b>7,00</b> (3,0)	<b>3,09</b> (0,0)	<b>0,0</b> (0,0)
Máximo	<b>87,49</b> (81,0)	<b>63,49</b> (61,0)	<b>1,04</b> (3,0)	<b>94,54</b> (102,0)	<b>54,03</b> (52,0)	<b>1,05</b> (4,0)
Média	<b>28,09</b> (26,69)	<b>12,12</b> (12,59)	<b>0,40</b> (0,54)	<b>23,30</b> (24,57)	<b>10,75</b> (10,99)	<b>0,25</b> (0,33)
Desvio padrão	<b>16,11</b> (16,44)	<b>9,52</b> (10,17)	<b>0,23</b> (0,72)	<b>19,83</b> (22,70)	<b>10,08</b> (10,99)	<b>0,21</b> (0,69)



Para além da proximidade entre as estatísticas descritivas dos dados observados e previstos, uma comparação direta de valores pode ser particularmente útil para identificar rapidamente como as previsões podem diferir das observações, o que não será óbvio pelas métricas de qualidade de ajuste fornecidas na Tabela 6.12. Apresenta-se, portanto, nas Figuras 6.19 e 6.20, a comparação direta de valores observados e previstos de *NASV* e *NACV* para os modelos da Pista Norte e Pista Sul, respectivamente.

Para o modelo PN\_3,5km\_2011\_2014, em termos de *NASV*, é clara a tendência de convergência entre os valores previstos e observados. Especialmente até 50 acidentes sem vítimas as previsões são bastante similares. Para valores superiores, embora o modelo se mostre capaz para identificar e prever locais com picos de acidentes, as magnitudes da observação e previsão nem sempre são tão próximas.

O comportamento para *NACV* também é satisfatório, havendo concordância entre valores reais e estimados. Nota-se, entretanto, que acima de 20 acidentes com vítimas, a diferença de magnitude entre observações e previsões é mais evidente para segmentos com valores máximos de acidentes. No modelo PN\_3,5km\_2015\_2018 o comportamento é similar, notando-se maior divergência entre observados e previstos para valores de Acidentes sem vítimas (*ASV*) acima de 30 e para valores de Acidentes com vítimas (*ACV*) acima de 15.





(a) PN\_3,5km\_2011\_2014





(b) PN\_3,5km\_2015\_2018

**Figura 6.19**– Comparação direta entre valores observados e previstos no conjunto de validação dos modelos da Pista Norte



(a) PS\_4km\_2011\_2014



(b) PS\_4km\_2015\_2018

**Figura 6.20** – Comparação direta entre valores observados e previstos no conjunto de validação dos modelos da Pista Sul

O desempenho do modelo PS\_4km\_2011\_2014 é bastante satisfatório, especialmente para NASV. Nesse caso, até o patamar de 70 acidentes sem vítimas verifica-se notável concordância entre os valores observados e previstos. Para segmento com alta acumulação de acidentes, como o com mais de 300 acidentes sem vítimas ocorridos, a previsão não foi muito acurada. Isso é de se esperar, uma vez que a ajuste global do modelo é bom, mas há dificuldade para modelar com precisão pontos discrepantes.

Quanto ao NACV, a tendência geral é de convergência, mas são observados desvios em alguns pontos. Ainda neste caso, a partir dos dados de validação o modelo conseguiu prever muito bem os valores para segmentos com maior número de acidentes. Tratam-se de valores não muito discordantes do intervalo {valor médio + 3 x desvio padrão} (Howell, 2010), diferente do caso verificado para NASV em que se excedeu, em mais de 4 vezes, esse intervalo podendo-se, inclusive, ser considerado um *outlier*. Isso reforça a adequação geral do modelo tanto aos dados de treinamento como de teste.

O modelo PS\_4km\_2015\_2018 teve desempenho comparável ao anterior, verificada alta convergência entre valores observados e previstos de acidentes sem vítimas especialmente até o patamar de 50 acidentes sem vítimas (ASV). Os picos de NASV são coincidentes, mas percebe-se que os valores previstos são geralmente inferiores aos observados. Para NACV, o desempenho geral também é adequado, observando-se desvios de magnitude em alguns picos. As previsões de NACM, apesar de não apresentadas nas imagens, oscilam basicamente entre 0,10 e 0,50, sem, contudo, revelar clara adequação de tendência entre valores observados e previstos; constatação válida para todos os modelos.

Comparando os modelos também foi possível concluir que, tanto para Pista Sul como para Pista Norte os modelos do período 2011-2014 é que têm melhor desempenho, principalmente para NASV. Numa análise global, apesar de alguns desvios revelados pelos gráficos, o que é razoável, todos os modelos selecionados apresentam boa concordância entre observações e previsões no conjunto de dados de validação, confirmando a aceitação de tais modelos.

Aliado às análises anteriores, para fins de avaliação conjunta e confirmação de desempenho, estão apresentadas no Apêndice C os gráficos de qualidade de ajuste e análise de resíduos para os quatro modelos selecionados. A análise centrou-se nos resultados de NASV e NACV já que, como discutido no capítulo anterior, os resultados de NACM não são consistentes. Para o

modelo PN\_3,5km\_2011\_2014 são notados pequenos desvios adicionais em relação aos resultados do treinamento para os *Q-Q Plot* de *NASV* e *NACV*. Nota-se maior dispersão, especialmente para *NACV*, em torno da reta de 45°. Os histogramas de resíduos apontam maior dificuldade, especialmente para *NACV*, de adequação dos resíduos à distribuição normal, não sendo, entretanto, comprometedor já que, os gráficos *Residual Q-Q* evidenciam desvios significativos em relação à reta de referência apenas nas extremidades dela.

Ainda com referência ao modelo de extensão de 3,5 km da Pista Norte no período 2011-2014, é verificada a adequação dos resíduos padronizados dentro das bandas de confiança e dispersão desejável. E ainda, os valores notavelmente baixos de *ACF* indicam a inexistência de autocorrelação nos resíduos. De forma geral, embora com ligeira queda de desempenho, os resultados do treinamento e validação deste modelo são convergentes. No outro modelo da Pista Norte, o PN\_3,5km\_2015\_2018, os desvios no *Q-Q Plot* e dispersão são mais evidentes. Verifica-se, em especial para *NACV*, menor consistência dos resíduos com a distribuição normal quando comparado aos resultados de treinamento. Apesar disso, os resíduos padronizados estão dispersos razoavelmente em torno do eixo horizontal zero e respeitam as bandas limítrofes de confiança. Também é perceptível a inexistência de autocorrelação nos resíduos, a partir dos valores resultantes de *ACF*. Mesmo diante da queda de performance do modelo, que passou de desempenho de alta magnitude no treinamento para média magnitude na validação, as constatações acima asseguram a aceitabilidade dos resultados do modelo para o conjunto de dados de teste.

O modelo PS\_4km\_2011\_2014 teve resultados de validação muito similares aos de treinamento, sendo o modelo com menor variação de performance. São raros os pontos desviantes nos gráficos *Q-Q Plot* e *Residual Q-Q Plot*; os resíduos têm distribuição aproximada da normal; os resíduos padronizados distribuem-se em torno de zero e dentro dos limites aceitáveis, com raros pontos discrepantes; e, verifica-se a inexistência de autocorrelação nos resíduos. Já no período seguinte, o modelo PS\_4km\_2015\_2018 apresenta maior dispersão e desvios no *Q-Q Plot*. De outro lado, o *Residual Q-Q Plot* e histograma de resíduos apontam para a adequação dos resíduos à distribuição normal. Os resíduos padronizados têm comportamento desejável e não é notada correlação nos resíduos, com base nos valores de *ACF*.

Mesmo diante da utilização de conjuntos de dados de teste pequenos, o que dificulta a convergência de resultados e gera prejuízo à qualidade de algumas métricas, os modelos

selecionados têm resultados aceitáveis também para os dados de validação, configurando sua validade preditiva.

### 6.3. VALIDAÇÃO ESTRUTURAL

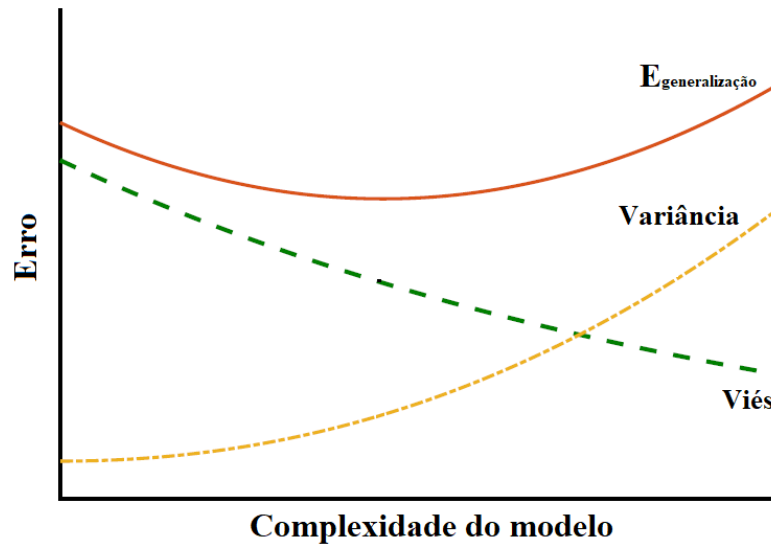
O objetivo da validação estrutural é verificar se a relação variável de entrada-variáveis resposta capturada pelo modelo (comportamento do modelo) é plausível com o conhecimento *a priori* do sistema que está sendo modelado. Note-se, contudo, que essa abordagem não permite determinar se o correto relacionamento subjacente entre as variáveis foi identificado, tendo sua utilidade centrada na identificação de modelos que não são plausíveis do ponto de vista físico. Tendo essa questão em tela, é importante apresentar o dilema viés-variância (*bias-variance tradeoff*), em que se busca um modelo que descreva bem os dados observados e, ao mesmo tempo, tenha a melhor capacidade de generalização para previsões.

A realidade nunca é suficientemente descrita em modelos, uma vez que os elementos que são empregados na modelagem constituem-se apenas como parte do fenômeno todo. Independente da quantidade e qualidade de dados, um modelo perfeito não pode ser obtido. A distância entre o verdadeiro sistema (realidade) e o melhor modelo obtido (realidade simulada) é o “erro de viés” do modelo ajustado. Por outro lado, tem-se que os dados medidos são sempre corrompidos por ruídos e distúrbios e, por conseguinte, também afetam as estimativas. Mesmo que uma descrição verdadeira do modelo esteja disponível, haverá discrepância entre ele e sua estimativa (causada pelos distúrbios), originando o “erro de variação” (variância) (LJUNG *et al.*, 2019). Segundo Mehta *et al.* (2019), o “viés” representa o melhor que o modelo poderia fazer se disponível quantidade infinita de dados de treinamento e a “variância” mede os erros típicos introduzidos no treinamento do modelo devido ao ruído de amostragem por ter um conjunto de dados finito.

Na Figura 6.21 está apresentado o esquema do dilema viés-variância. Observa-se que à medida que o modelo torna-se mais complexo, o erro de generalização diminui, reduzindo também o viés e aumentando a variância. Em dado momento, diante da amostra de teste, o modelo se torna muito complexo frente a quantidade de dados e o erro de generalização aumenta devido à alta variabilidade (AZEVEDO, 2018). De um lado, maior variância e menor viés implica num modelo que descreve bem os dados observados, mas tem capacidade de generalização comprometida. De outro, quando a variância é muito baixa geralmente o erro de viés é alto,



conduzindo a inadequação de ajuste do modelo aos dados e também dificuldade de generalização (BILL, 2015). Deve-se, portanto, buscar o balanceamento entre o viés e a variância.



**Figura 6.21**– Representação do dilema viés-variância  
Fonte: Mehta *et al.* (2019) adaptado

Esse dilema viés-variância também tem desdobramentos na comparação entre a abordagem estatística e de aprendizado de máquina na modelagem de dados. Conforme Breiman (2001), a abordagem estatística busca acima da capacidade de predição, extrair informações de associação entre as variáveis explanatórias e variáveis resposta, a fim de subsidiar análises de inferência e causalidade. Para Kuhn e Johnson (2013), o emprego de AM tem por principal objetivo projetar com precisão a probabilidade (ou número esperado) de ocorrência de determinado evento. O foco desse tipo de modelagem é otimizar a precisão da previsão.

As implicações disso é que, como o interesse da estatística é o entendimento dos dados, os modelos precisam ser altamente interpretáveis, o que induz a necessidade de simplicidade dos modelos (baixa variância, mas alto viés). No caso dos modelos de AM, que têm por foco a acurácia dos resultados, o viés é muito baixo já que existem poucos pré-requisitos e suposições sobre os dados. Contudo, isso implica em um modelo muito complexo e de difícil interpretação.

Surge, então, um novo dilema: acurácia *versus* interpretabilidade. Luo *et al.* (2019) apontam que, de forma geral, os modelos mais acurados são os de menor interpretabilidade e, em oposição, os modelos altamente interpretáveis tendem a ter baixo desempenho de predição. As

características dos modelos com maior acurácia são relações não lineares e não suaves, e longo tempo de processamento; e dos modelos de maior interpretabilidade: relações lineares e suaves, relacionamentos bem definidos e facilidade de processamento computacional.

Breiman (2001), adaptando o princípio da navalha de Occam, afirma que a precisão geralmente requer métodos de previsão mais complexos, ao passo que funções simples e interpretáveis não tornam um preditor mais preciso. De forma mais contundente, Kuhn e Johnson (2013) defendem que um modelo criado para fins de previsão, como é o objetivo desta tese, não deve ser limitado pelo requisito de interpretabilidade e ainda, caso o modelo possa ser validado adequadamente, não é muito importante se é uma “caixa preta” ou um modelo simples e interpretável.

Diante da confirmação de boas métricas de previsão, apresentadas nas seções 6.1 e 6.2, na tentativa de ainda tirar proveito dos modelos de RNA para interpretabilidade do fenômeno modelado, foram empregados alguns métodos propostos na literatura. No caso dos modelos MVLPN são apresentados os coeficientes e demais parâmetros estimados dos modelos selecionados, tendo sido conduzida ainda uma seleção *backward* adaptada para que os modelos finais fossem compostos apenas por variáveis estatisticamente significativas.

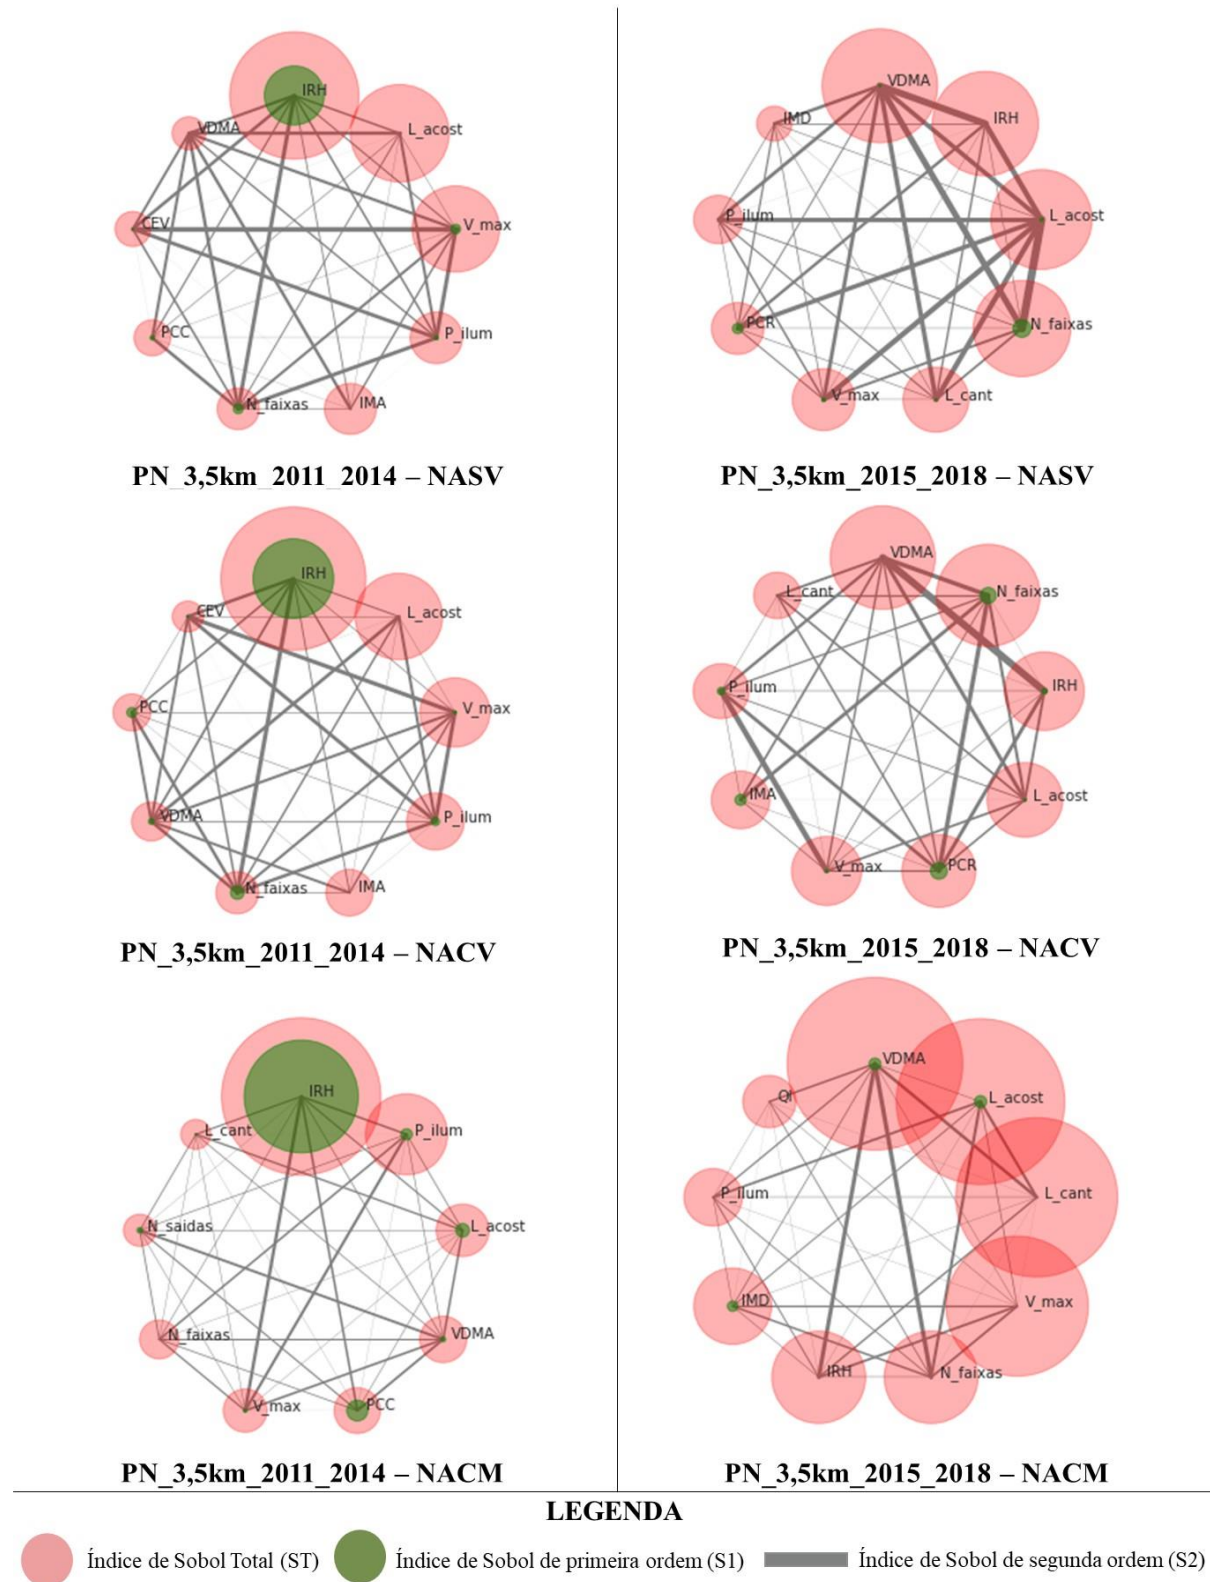
### **6.3.1. Validação dos Modelos de RNA**

Para a validação estrutural dos modelos de RNA foram empregados quatro métodos que se mostraram mais adequados, são eles: índice de Sobol’, índice de Morris, perfil de sensibilidade e fator de importância.

#### **(i) Índice de Sensibilidade de Sobol’**

Para uma visualização mais completa e compreensível, gráficos contendo a interação dos três índices (S1 – mede o efeito direto de cada parâmetro para a variação da saída do modelo, S2 – mensura a contribuição de interações de variáveis em pares para a variação da saída e ST – inclui os efeitos de primeira ordem e ordens superiores) foi confeccionado. O tamanho do círculo vermelho e verde corresponde ao índice total e índice de primeira ordem, respectivamente; e a largura das linhas de conexão entre as variáveis indica a importância relativa da interação de cada par na variação da saída. Por questões de apresentação visual são

consideradas as nove variáveis com maiores valores de índice de Sobol' total (ST), tendo-se verificado ainda que as demais variáveis não têm valores muito expressivos dos índices de Sobol'. Na Figura 6.22 estão apresentados os resultados para os modelos da Pista Norte.



**Figura 6.22** – Índices de Sobol' dos modelos da Pista Norte

Para o modelo PN\_3,5km\_2011\_2014, nota-se a predominância do inverso de raio de curva (*IRH*) como variável mais influente em todos os níveis de severidade. Essa variável sozinha contribui para 20,13%, 25,65% e 36,13% da variabilidade das saídas *NASV*, *NACV* e *NACM* do modelo, respectivamente. E, ao contabilizar os efeitos decorrentes da interação com outras variáveis (*ST*), passa a explicar, respectivamente, 38,38%, 43,26% e 47,68% da variação das saídas *NASV*, *NACV* e *NACM*. Percebe-se ainda, que essa variável interage especialmente com o número de faixas (*N\_faixas*), número de controladores eletrônicos de velocidade (*CEV*) e volume de tráfego (*VDMA*) para acidentes sem vítimas e com vítimas. No caso de *NACM*, a mais forte interação ocorre com a velocidade regulamentada da via (*V\_max*).

De seguida, as variáveis *L\_acost* (largura do acostamento) e *V\_max* é que figuram com maior importância para explicar a variação das saídas *NASV* e *NACV*. Para os acidentes com mortes *P\_ilum* (proporção de iluminação artificial no segmento) e *L\_acost* que são as variáveis mais influentes. Em todos esses casos, diferente do *IRH*, a maior contribuição das variáveis se dá pela interações com outras variáveis e não por seu efeito direto. O conjunto de dez variáveis mais influentes para variação de *NASV* e *NACV* é o mesmo (embora com diferenças na ordem das variáveis); já para os acidentes com mortes deixa de ter grande importância os *inputs IMA* e *CEV*, dando lugar a *L\_cant* e *N\_saídas*. Por meio desse método de análise de sensibilidade é possível concluir que os acidentes de trânsito sem vítimas e com vítimas são predominantemente explicados por três variáveis: *IRH*, *L\_acost* e *V\_max*, com algumas contribuições a partir dos parâmetros *P\_ilum*, *IMA*, *N\_faixas*, *VDMA*, *PCC*, *CEV*, *L\_cant*, *N\_saídas*, *IMD* e *QI* e, um impacto negligenciável dos demais parâmetros (*PCR*, *N\_acessos*, *Div\_pista\_B*, *Div\_pista\_C*, *Uso\_solo\_U*, *Uso\_solo\_R*).

Alguns resultados confirmam o que era de se esperar em termos de comportamento de algumas variáveis, no entanto, é patente que o *VDMA* não figura entre as variáveis mais influentes para *NASV* (valor de *ST* inferior a 0,10) e *NACV*, o que é não muito razoável. Ainda analisando a Figura 6.37, mas em termos do modelo PN\_3,5km\_2015\_2018, observa-se que o *VDMA* passa a ser o mais importante para explicar a variação do número de acidentes segundo os três níveis de severidade. Ainda assim, constata-se que a influência do volume de tráfego para variação do número de acidentes é predominantemente fruto da interação com outras variáveis, especialmente *IRH*, *N\_faixas* e *L\_acost*. Para o *NACM* o *IRH* deixa de ser tão importante dando lugar a *L\_cant*.

Para *NASV* e *NACV* os fatores mais influentes são *VDMA*, *IRH*, *L\_acost* e *N\_faixas*, com contribuições de *L\_cant*, *V\_max*, *PCR*, *P\_ilum*, *IMD* e *IMA* e, assim como para o período 2011-2014, influência insignificante de *Div\_pista\_B*, *Div\_pista\_C*, *Uso\_solo\_R*, *Uso\_solo\_U*. Para os acidentes fatais, além do *VDMA*, os fatores mais importantes são *L\_acost*, *L\_cant* e *V\_max*.

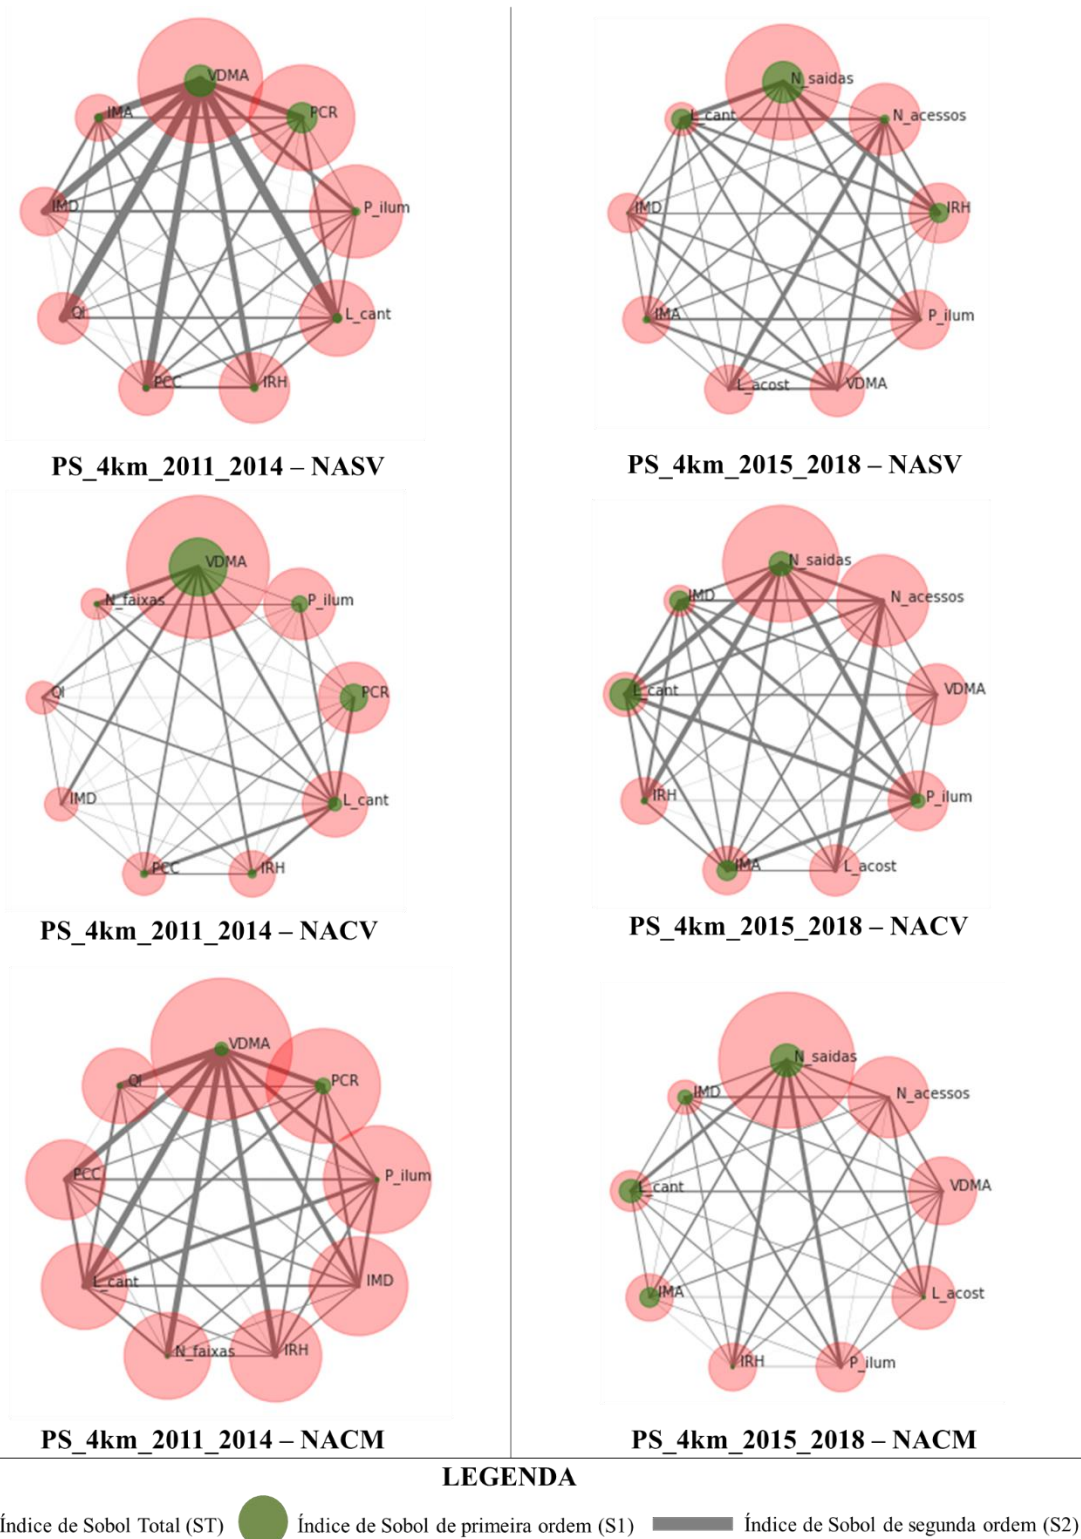
A interpretabilidade desse modelo parece mais adequada, haja vista a importância principal do *VDMA* para a variação no número de acidentes, o que é intuitivo e consensual por se tratar de uma variável de exposição. Além disso, as variáveis *IRH*, *L\_acost* e *N\_faixas* apresentam importante influência para o número de acidentes sem vítimas e com vítimas em ambos os modelos (*PN\_3,5km\_2011\_2014* e *PN\_3,5km\_2015\_2018*), sinalizando ser fatores relevantes para a ocorrência de acidentes na Pista Norte.

Em termos da Pista Sul, estão apresentados na Figura 6.23 os resultados para os dois modelos selecionados. No período 2011-2014 nota-se a predominância da influência do *VDMA*, com efeito direto sobre a variação do número de acidentes sem vítimas, com vítimas e com mortes, especialmente, devido à sua interação com outras variáveis. Embora com algumas inversões de ordem, o conjunto das dez variáveis mais influentes é o mesmo para *NASV*, *NACV* e *NACM*. As principais variáveis, além do volume de tráfego, são *PCR*, *P\_ilum* e *L\_cant* para os acidentes com e sem vítimas e, *PCR*, *P\_ilum*, *IMD*, *IRH*, *N\_faixas* e *L\_cant* para acidentes com mortes. E ainda, assim como na PN, *Div\_pista\_B*, *Div\_pista\_C*, *Uso\_solo\_U* e *Uso\_solo\_R* são as variáveis menos importantes para a variação do número de acidentes em qualquer nível de severidade.

Para o modelo *PS\_4km\_2015\_2018*, o volume de tráfego perde importância, passando do mais influente no período 2011-2014 para quinto mais influente para *NASV* e terceiro mais influente para *NACV* e *NACM*. Nesse modelo as variáveis mais importantes são *N\_saídas* e *N\_aceessos*. Mesmo diante da suposição de existência de relação entre o número de acessos e saídas da rodovia e os acidentes ocorridos, não há razão muito óbvia para que tais fatores figurem como principais, especialmente por não o serem no período 2011-2014 (na verdade eram pouco importantes) e por serem atributos que mantiveram-se inalterados no período de tempo analisado.

A variável *N\_saídas* tem sua maior componente devido a interação com outras variáveis, principalmente para os acidentes com mortes. Observa-se também que as nove variáveis mais

influentes para ocorrência de acidentes são as mesmas para todos os níveis de severidade. E por fim, constata-se que o tipo de uso do solo e tipo de divisão de pista são as variáveis que menos contribuem para a variação do número de acidentes, independente de qual tipo.




**Figura 6.23 – Índices de Sobol' dos modelos da Pista Sul**

Algumas constatações corroboram com o que se espera em termos de relação entre variáveis, enquanto outras não parecem ter explicação clara para ocorrer. Apesar disso, considerando as dez variáveis mais influentes para cada saída (*NASV*, *NACV* e *NACM*) e para cada pista e período de tempo, tem-se que, em termos de efeitos totais, as variáveis *VDMA*, *IRH*, *P\_ilum* e *L\_cant* sempre estão presentes nesses conjuntos. Isso sinaliza que, embora não figurando necessariamente como mais importantes, tais variáveis, em diferentes cenários, mantiveram-se como influentes. Ainda que com ressalvas, afirma-se então que, no contexto geral, são tidas como as variáveis de maior contribuição para ocorrência de acidentes no trecho da rodovia analisada. E de outro lado, *Div\_pista\_B*, *Div\_pista\_C*, *Uso\_solo\_U* e *Uso\_solo\_R* são as variáveis que menos explicam a variação do número de acidentes.

(ii) Método de Morris


A princípio são apresentadas nas Figuras 6.24, 6.25 e 6.26 os valores de  $\mu^*$  cada variável em cada um dos modelos para *NASV*, *NACV* e *NACM*, respectivamente. Médias ( $\mu^*$ ) altas significam alta influência na variável dependente, enquanto que altos desvios padrão ( $\sigma$ ) significam elevado comportamento não linear da variável.



**Figura 6.24** – Valores da média dos efeitos elementares para *NASV*

Para *NASV*, por exemplo, as variáveis que mais impactam nos modelos da Pista Norte são *IRH*, *V\_max*, *L\_acost*, *P\_ilum* (em 2011-2014), *IMD* (em 2011-2014), *PCR* (em 2015-2018) e *N\_faixas* (em 2015-2018). Na Pista Sul as variáveis mais influentes são *IRH*, *P\_ilum*, *PCR* (em 2011-2014), *L\_cant* (em 2011-2014), *N\_acessos* (em 2015-2018), *IMA* e *N\_saídas* (em 2015-2018). E ainda, constata-se que *IRH* é uma variável importante em todos os modelos.

Em termos de acidentes com vítimas, os conjuntos de variáveis mais influentes são similares. Na Pista Norte as principais variáveis são *IRH*, *V\_max*, *L\_acost* (em 2011-2014), *P\_ilum* (em 2011-2014), *PCR*, *N\_faixas* (em 2015-2018) e *IMA* (em 2015-2018). Na Pista Sul as variáveis que se destacam são: *IRH* (em 2011-2014), *P\_ilum*, *PCR* (em 2011-2014), *L\_cant*, *N\_acessos* (em 2015-2018), *IMA* e *N\_saídas* (em 2015-2018). Dessas variáveis, *IRH*, *P\_ilum*, *PCR* e *IMA* ocorrem como principais em três dos quatro modelos.




**Figura 6. 25** – Valores da média dos efeitos elementares para NACV

Para *NACM*, *L\_acost*, *P\_ilum*, *L\_cant* (em 2015-2018), *IRH*, *N\_faixas* (em 2015-2018), *PCR* (em 2011-2014) e *V\_max* (em 2011-2014) são as variáveis mais importantes. Já na Pista Sul a concordância entre os modelos é só para *P\_ilum*, as demais são: *IMD*, *IRH*, *N\_faixas* e *PCR* no período 2011-2014 e, *N\_saídas*, *N\_acessos*, *IMA* e *L\_acost* no período de 2015 a 2018. Note-se que *P\_ilum* é a única variável que ocorre entre as mais importantes em todos os modelos.

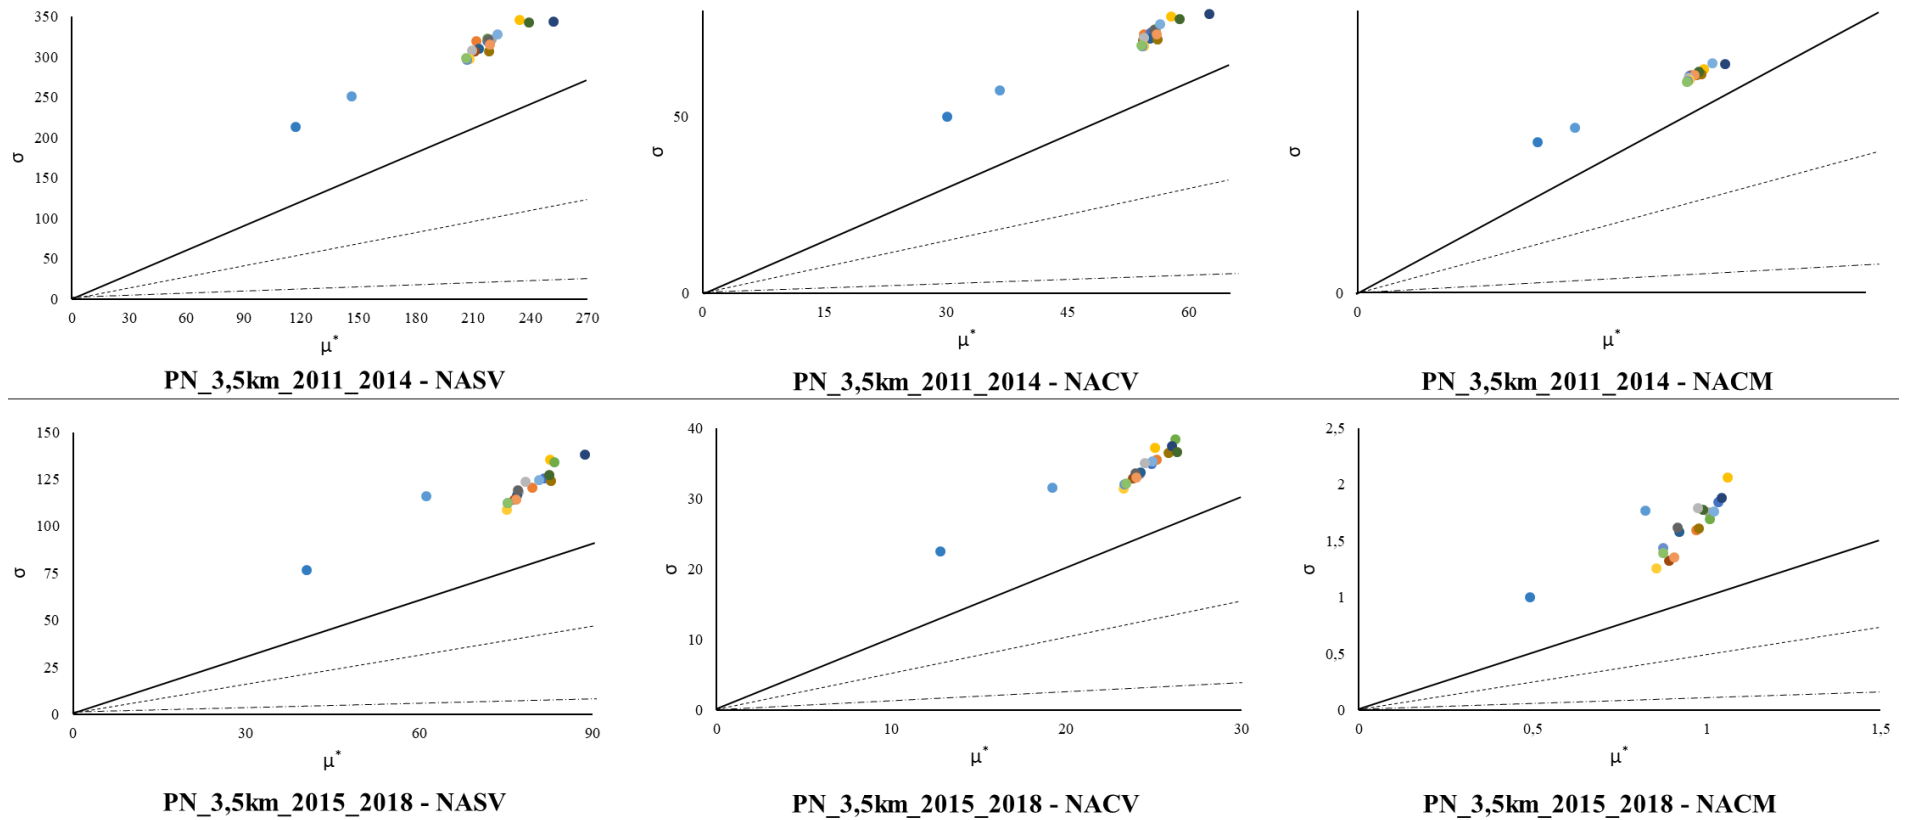


As principais variáveis verificadas por meio de  $\mu^*$  também foram tidas como mais influentes pelo índice de Sobol', em pelo menos um modelo. A recíproca, no entanto, não é verdadeira. Como é de se notar, em nenhum dos casos o volume de tráfego figurou como principal, pelo contrário, sempre foi verificado com os menores valores de  $\mu^*$ . Ainda é importante ressaltar que, conforme Morris (1991), o valor numérico da média não é útil em termos quantitativos, mas apenas qualitativos. Em outras palavras, é possível verificar qual variável é mais ou menos influente que outra, mas não o quanto é mais ou menos influente.




**Figura 6. 26** – Valores da média dos efeitos elementares para NACM

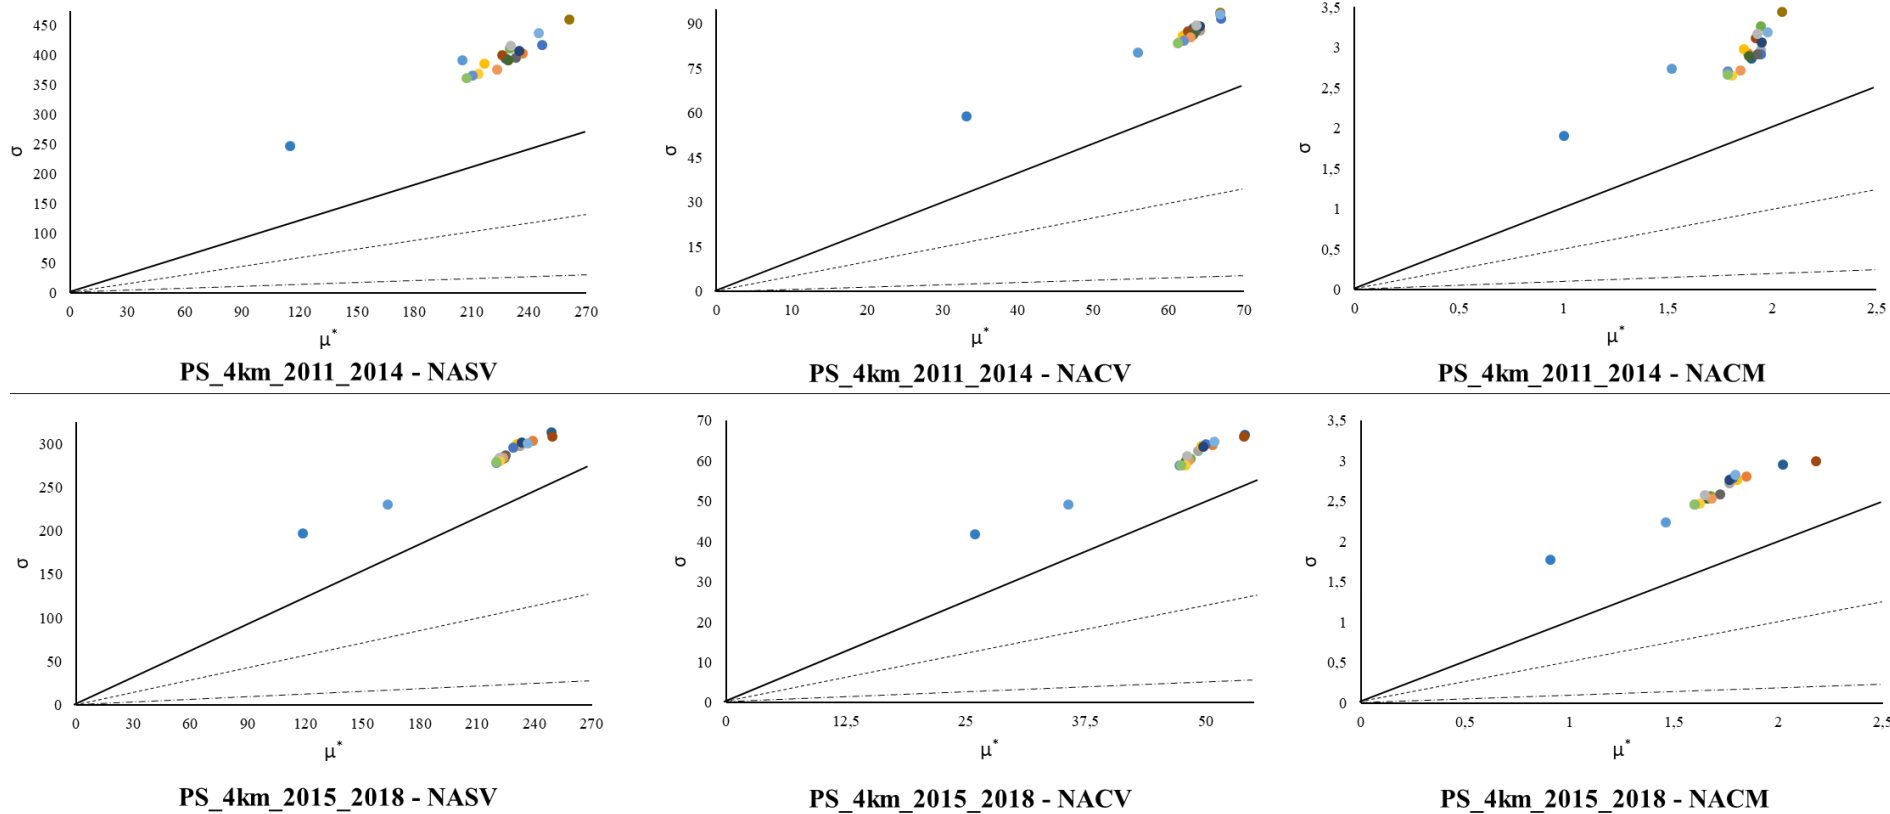
De forma complementar, a relação  $\sigma / \mu^*$  nos permite avaliar alguns aspectos do comportamento das variáveis. Num gráfico, os parâmetros que estão abaixo da reta  $\sigma / \mu^* = 0,1$  podem ser considerados como relação quase linear com os resultados; se eles estiverem abaixo das linhas  $\sigma / \mu^* = 0,5$  e  $\sigma / \mu^* = 1$  possuem, respectivamente, comportamento monotônico e quase monotônico; por fim, acima da linha  $\sigma / \mu^* = 1$  os parâmetros apresentam alta relação não linear com os resultados e fortes indícios de interação com outros fatores de entrada. Nas Figuras 6.27 e 6.28 estão apresentados os gráficos correspondentes aos modelos da Pista Norte e Pista Sul, respectivamente.



**LEGENDA**



**Figura 6. 27** – Diagrama de Morris para modelos da Pista Norte



**LEGENDA**

- |        |         |          |           |          |               |               |              |              |       |                              |
|--------|---------|----------|-----------|----------|---------------|---------------|--------------|--------------|-------|------------------------------|
| ● VDMA | ● IMA   | ● IMD    | ● L_acost | ● L_cant | ● N_faixas    | ● N_acessos   | ● N_saidas   | ● PCC        | ● PCR | — $\sigma / \mu^* = 1,0$     |
| ● IRH  | ● V_max | ● P_ilum | ● CEV     | ● QI     | ● Div_pista_B | ● Div_pista_C | ● Uso_solo_R | ● Uso_solo_U |       | - - - $\sigma / \mu^* = 0,5$ |
|        |         |          |           |          |               |               |              |              |       | - · - $\sigma / \mu^* = 0,1$ |

**Figura 6.28** – Diagrama de Morris para modelos da Pista Sul

O comportamento de todos os gráficos é bastante similar. Todos os pontos, indicativos das variáveis, estão acima da reta  $\sigma / \mu^* = 1$ . Isso significa que todas as variáveis têm um relacionamento altamente não linear com as variáveis dependentes e/ou interagem com outras variáveis explicativas (efeito de segunda ordem).

No modelo PN\_3,5km\_2011\_2014 a variável *IRH* é a que possui maior  $\mu^*$  e também maior  $\sigma$ , implicando em afirmar que trata-se da variável mais influente na ocorrência de acidentes sem vítimas, com vítimas e com mortes e, ao mesmo tempo, revelou ter o maior comportamento não linear. As outras variáveis acumulam-se numa região próxima ao ponto de *IRH*, ao passo que *Uso\_solo\_U* e *VDMA* estão visivelmente afastadas da massa dessas variáveis. Em todas as saídas (*NASV*, *NACV* e *NACM*) o uso do solo do tipo urbano é tido como a variável menos influente e com menor comportamento não linear (embora na região de alta não linearidade) entre as variáveis. Em seguida, com comportamento similar está o volume de tráfego.

Para o período 2015-2018, outro modelo da Pista Norte tem comportamento semelhante. Contudo, verifica-se *IRH* como variável mais influente e de comportamento mais não linear para *NASV*, *N\_faixas* para *NACV* e *L\_acost* para *NACM*. Novamente observa-se as variáveis *Uso\_solo\_U* e *VDMA* como pontos discrepantes da massa de pontos, sendo a primeira de menor influência para as variáveis dependentes e de menor comportamento não linear. Ainda assim, observa-se que o *VDMA* está mais próximo das demais variáveis, em comparação com o período 2011-2014, e está entre as variáveis com maior comportamento não linear para *NACM*.

De forma equivalente ocorre nos modelos da Pista Sul. Para o período 2011-2014 verifica-se *PCR* como sendo a variável mais influente e de maior comportamento não linear e, noutro extremo, o *Uso\_solo\_U* como a variável de menor influência e menor comportamento não linear. O *VDMA*, a exemplo dos modelos da PN, continua sendo o de segunda menor influência, mas notavelmente mais próximo das demais variáveis, especialmente para *NASV*.

Por fim, no modelo PS\_4km\_2015\_2018 tem-se *N\_saídas* como a variável mais influente e não linear para *NASV* e *NACM* e, *N\_acessos* como a mais importante e não linear para *NACV*. E ainda, o comportamento de *Uso\_solo\_U* e *VDMA* é o mesmo verificado nos demais modelos.

Ademais, mesmo que o diagrama de Morris também seja capaz de revelar, investigou-se o comportamento monotônico das variáveis. A monotonia pode ser avaliada, para cada *input*, por meio da razão  $\mu/\mu^*$ , sendo o valor 1,0 (ou próximo a isso) indicativo de monotonia positiva e -1,0 (ou próximo disso) de monotonia negativa. O valor máximo verificado foi de 0,63 para *IRH* no modelo PN\_3,5km\_2011\_2014, não se confirmando o comportamento monotônico em nenhuma das variáveis.

Como destacado por Morris (1991), a utilização do método deve ser centrada na avaliação qualitativa, de forma que são estas as principais conclusões passíveis de extração: todas as variáveis apresentam comportamento não linear e/ou interação com outras variáveis explicativas; *Uso\_solo\_U* é a variável menos influente em todos os modelos; *VDMA* é a segunda variável menos influente em todos os modelos; *IRH* é a variável mais influente para todas as saídas do modelo PN\_3,5km\_2011\_2014; *PCR* é a variável mais influente para todas as saídas do modelo PS\_4km\_2011\_2014.

De acordo com Branger *et al.* (2015), a não linearidade referida é tida como a não linearidade de uma variável individual (independente de outros valores de entrada, uma alteração na entrada *i* tem um impacto muito diferente na saída, a depender de onde ela ocorre no intervalo de variação) enquanto que interações são entendidas como situação em que a mesma mudança na variável *i* tem um impacto muito diferente na saída, dependendo do valor de outros parâmetros. O método de Morris não é capaz de distinguir não linearidade e interações. Por outro lado, o método de Sobol' é capaz de detectar as interações existentes entre as variáveis.

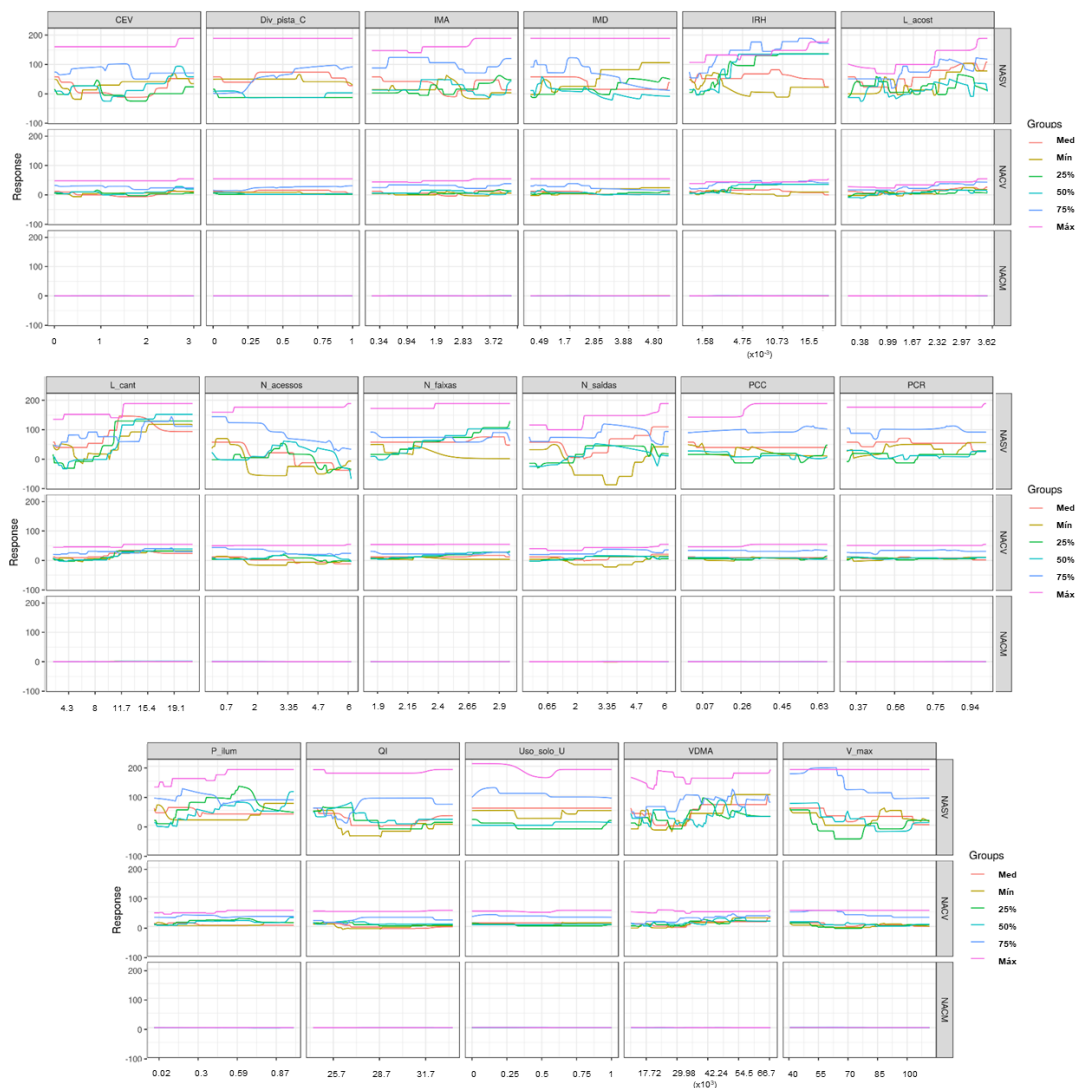
Deste modo, resgatando as constatações obtidas pelo método de Sobol', em que se verificou que a predominância da variação nas variáveis dependentes em função de uma variável explicativa decorre de sua interação dela com outras variáveis e não do seu efeito direto, confirma-se as interações entre variáveis de entrada e potencial comportamento não linear.

### (iii) Método do Perfil de Sensibilidade

O método do perfil de sensibilidade tem como resultado seis perfis em termos da variação na saída no intervalo da variável de entrada de interesse. A título de exemplo, mostrado na Figura 6.29 estão os perfis de sensibilidade do modelo PN\_3,5km\_2011\_2014 e ainda, na Figura 6.30

detalhes do comportamento das variáveis *VDMA*, *IRH* e *N\_saídas*. Um modelo plausível é aquele que produz resultados aproximadamente dentro do intervalo de dados observados e exibe relações razoavelmente monotônicas entre a variável de interesse e a variável dependente quando as demais variáveis explicativas são fixas (HUMPHREY *et al.*, 2017).

Para o volume de tráfego, por exemplo, espera-se que haja uma relação positiva decrescente, especialmente para os acidentes sem vítimas, em que a medida que o volume de tráfego aumenta o número de acidentes também seja incrementado, mas a taxa cada vez menores (HAUER, 1997; LORD, 2002, LORD & PARK, 2008). Também há previsibilidade no comportamento em termos de curvatura horizontal já que, conforme alguns autores (VAN DER HORST & RIDDER, 2007; CHEN, 2010; COSTA, 2013; JAMSON *et al.*, 2015; CAFISO *et al.*, 2018) verifica-se que raios menores conduzem a maior ocorrência de acidentes.




**Figura 6.29** – Perfil de sensibilidade das variáveis explicativas – PN\_3,5km\_2011\_2014

Ao analisar os gráficos, considerando o conjunto das curvas, constata-se que os modelos PN\_3,5km\_2011\_2014 e PS\_4km\_2011\_2014 têm os limites máximos de valores previstos bem próximos aos limites verificados nos dados observados. Ainda assim, em todos os modelos são observados valores negativos (embora com diferentes magnitudes) para *NASV* e *NACV*, o que não faz sentido físico para o fenômeno em estudo. Nos modelos da Pista Norte os valores negativos de acidentes, especialmente sem vítimas, ocorrem notavelmente nas variáveis: *N\_acessos*, *N\_saídas*, *V\_max*, *Div\_pista\_C*, *L\_acost*, *N\_faixas*, *PCC* e *Uso\_solo\_U*. Na Pista Sul, no modelo do período 2011-2014 foram observados valores negativos em todas as variáveis, especificamente na curva “Mín.” (curva em que as demais variáveis explicativas são fixadas em seu valor mínimo enquanto varia-se os valores da variável de interesse). Já no outro modelo, para todas as variáveis houve a ocorrência de uma ou mais curvas com trajetória entre valores negativos de acidentes sem vítimas.

Além disso, quando da análise das curvas de comportamento das variáveis não é notada congruência entre elas em cada conjunto, para a respectiva variável. Explicando melhor, ocorrem diversos casos em que, para um mesmo valor da variável de interesse, a depender do quartil em que as demais estão fixadas, os resultados obtidos são contrários. A título de exemplo, no primeiro modelo da Pista Norte (Figura 6.30) observa-se para a variável *N\_saídas* para *NASV* que, numa tendência geral, as curvas “Mín.” (cor bege) e “75%” (cor azul) se contrapõem já que, para os mesmos valores, enquanto uma tem comportamento crescente a outra decresce.

Voltando-se a atenção para a curva “Med.”, que representa a variação mediana da saída no intervalo de valores da variável explicativa de interesse, ainda são notados valores negativos em algumas variáveis, ainda que de baixa magnitude. Avaliando os modelos em relação as variáveis *IRH* e *VDMA*, que como discutido tem um comportamento típico esperado, nota-se que para a Pista Norte o aumento de *IRH* (e conseqüente diminuição do raio de curva) leva a redução do número de acidentes sem vítimas no primeiro modelo enquanto que experimenta comportamento oscilante (à medida que o *IRH* é maior, ora o *NASV* diminui, ora aumenta) no segundo período. Nos modelos da Pista Sul a tendência de acidentes sem vítimas é crescente a medida que o *IRH* é maior, como esperado.



**Figura 6.30** – Perfil de sensibilidade das variáveis VDMA, IRH e N\_saídas – PN\_3,5km\_2011\_2014

Em termos de volume de tráfego, para PN\_3,5km\_2011\_2014 observa-se uma queda a partir do valor 18.000, onde são esperados zero acidentes sem vítimas até cerca do  $VDMA = 35.000$ , seguido de uma retomada de valores após esse patamar. No outro modelo da Pista Norte nota-se um patamar de estabilidade até aproximadamente  $VDMA = 35.000$ , seguida de uma suave tendência crescente até leve queda junto aos valores máximos. No primeiro modelo da Pista Sul verifica-se um patamar quase horizontal para valores iniciais de volume, experimentando-se uma queda e novo patamar entre os valores aproximados de 37.000 a 50.000, seguido de ligeiro crescimento e suave queda para os valores máximos. Por fim, no modelo PS\_4km\_2015\_2018 nota-se tendência crescente e patamar de estabilização até  $VDMA = 44.000$  a partir de onde a tendência passa a ser de decréscimo e leve aumento para os valores finais de volume de tráfego.

Como observado para essas duas variáveis, o comportamento verificado para os modelos da Pista Norte não se apresenta como o esperado enquanto que os modelos da Pista Sul podem ser tidos como aceitáveis. Apesar disso, em nenhum caso a escala de valores esperados de acidentes é razoável, auferindo-se valores negativos, extenso patamar de zero e amplitude restrita de valores previstos.



A ocorrência de combinações improváveis também pode ter contribuído para resultados pouco condizentes. Variáveis numéricas inteiras, a exemplo de número de controladores eletrônicos (*CEV*), número de faixas (*N\_faixas*), número de acessos (*N\_acessos*) e número de saídas (*N\_saídas*), velocidade regulamentada da via (*V\_max*), por exemplo, nunca ocorrem com valores decimais no cenário real.

De modo similar, as variáveis referentes a divisão de pista e uso do solo foram concebidas para indicar a existência ou inexistência de determinada característica e não deveriam assumir valores diferentes de 0 ou 1. Fato é que para as simulações tais variáveis assumem valores que nunca ocorrerão na realidade – já que para a modelagem essas variáveis foram assumidas como de valores inteiros – e, considerando que as redes neurais têm seu funcionamento baseado no aprendizado a partir dos dados, esse pode ser um ponto crítico. Ademais, a complexidade da arquitetura da rede foi útil para o ajuste do modelo e boas previsões de número de acidentes, mas dificulta a captura do relacionamento entre os dados.

Embora pouco interpretáveis e de confiabilidade limitada, os perfis revelam as complexas relações existentes entre as variáveis, não sendo observada monotonicidade nas variáveis explicativas. Isso reforça as constatações feitas por meio da aplicação do método de Sobol' e de Morris, em que foram verificou-se a alta interação de uma variável com as demais para causar variação na saída. Adicionalmente, a semelhança de escala de valores previstos de acidentes para todas as variáveis a cada modelo, sinalizam que a RNA tira proveito da informação que cada uma delas fornece para prever as saídas. Apesar do método de perfil de sensibilidade não tenho sido útil para a interpretabilidade do modelo, os seus resultados corroboraram com o que foi apurado pelos outros métodos.

#### (iv) Fator de importância

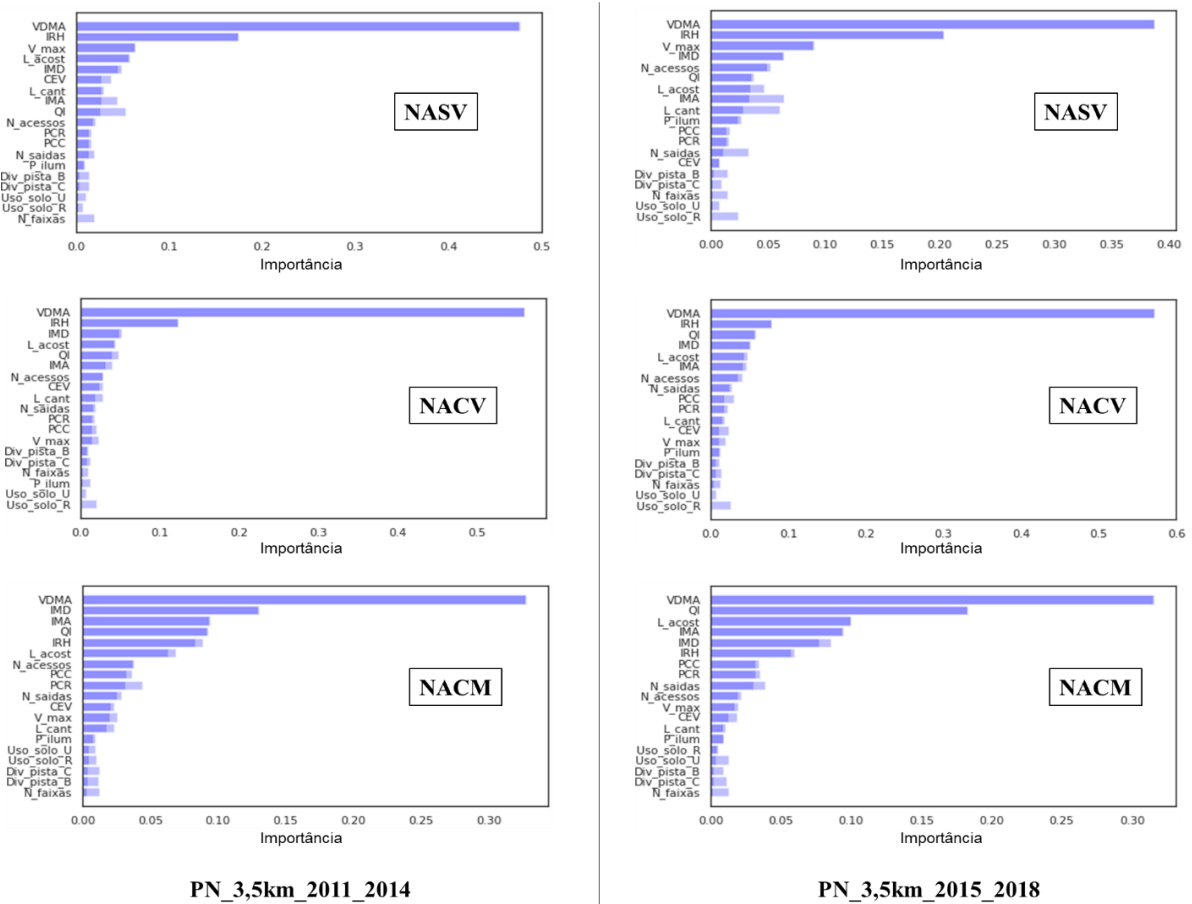
O emprego de *Random Forest* permitiu o cálculo do fator de importância relativa de cada variável explicativa. Embora não seja possível, por meio dessa medida, estabelecer a forma de relacionamento entre o *input* e a variável de saída, ela permite identificar as variáveis mais influentes no modelo, o que é de grande utilidade.

Nas Figuras 6.31 e 6.32 estão apresentados os resultados para os modelos da Pista Norte e Pista Sul, respectivamente. A barra em cor sólida representa a importância média da variável

enquanto que a barra com transparência refere-se ao valor máximo de importância que essa variável apresentou.

Para todas as saídas e em todos os modelos o volume de tráfego figura como variável mais importante e ainda com valores sensivelmente maiores que as demais variáveis. Em ambos modelos da Pista Norte, na sequência do *VDMA*, o *IRH* é apontado com segundo fator mais importante tanto para acidentes sem vítimas como para acidentes com vítimas. Adicionalmente, *V\_max* para *NASV* e *IMD* e *QI* para *NACV* foram as outras variáveis mais importantes. No caso dos acidentes com mortes, além do volume de tráfego tem grande importância as variáveis *IMD*, *IMA* e *QI* para o período 2011-2014 e, *QI*, *L\_acost* e *IMA* para o período 2015-2018.

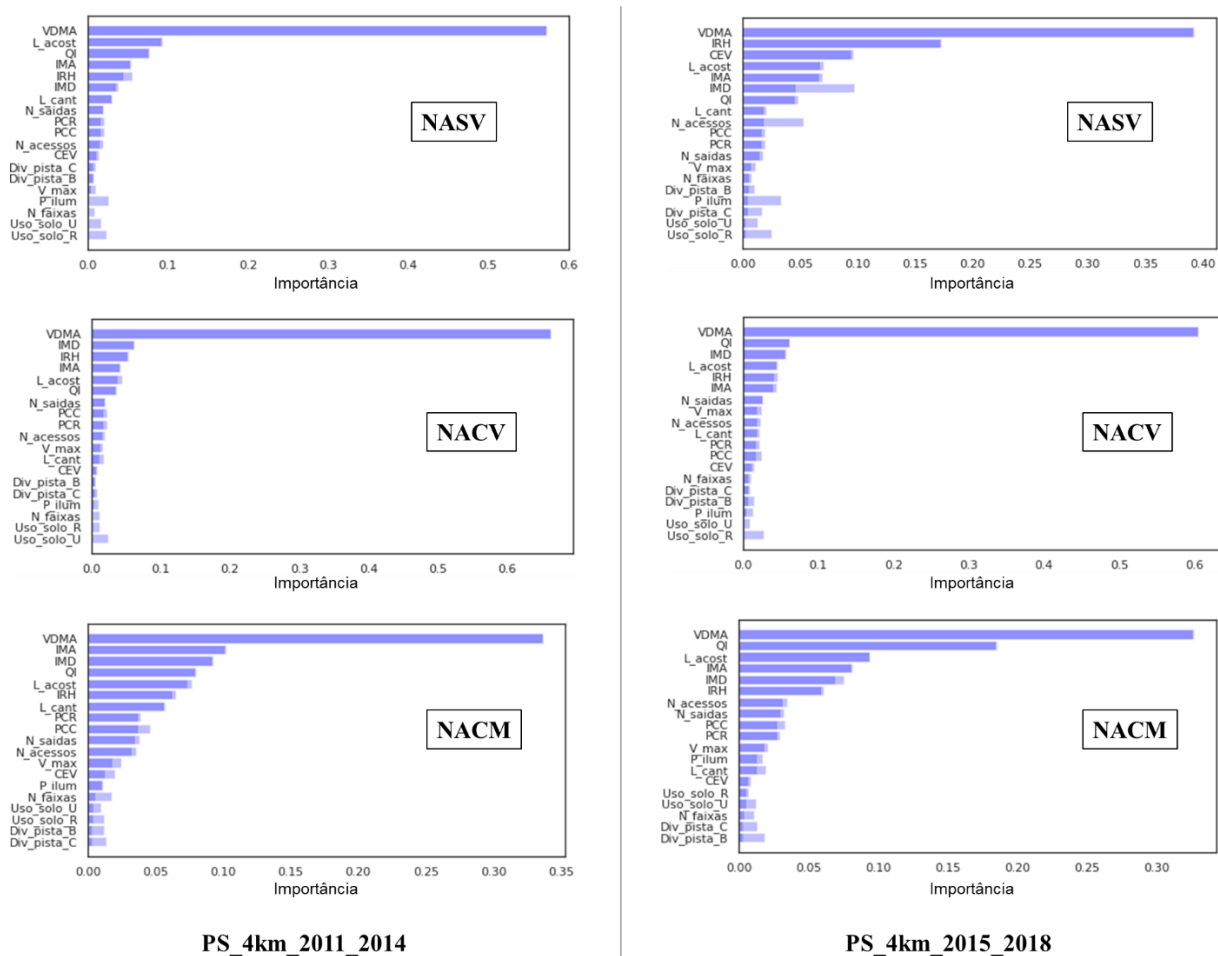
As demais variáveis apresentam importância bem inferior a 10% e são, portanto, pouco significativas. Ainda se observa que as variáveis menos importantes, em todos os casos dos modelos da Pista Norte são *Uso\_solo\_U*, *Uso\_solo\_R* e *N\_faixas*.



**Figura 6.31**– Fatores de importância dos modelos selecionados da Pista Norte

Para os modelos da Pista Sul o volume de tráfego também é o principal fator para ocorrência dos acidentes em todas as severidades. Já em termos do segundo mais importante, diferente dos modelos da Pista Norte em que *IRH* foi verificado como tal, basicamente cada modelo e cada saída tem uma variável distinta, sendo elas: *L\_acost* e *IRH* para acidentes sem vítimas, *IMD* e *QI* para acidentes com vítimas e, *IMA* e *QI* para acidentes com mortes.

As demais variáveis têm importância inferior a 10%, sendo observado *Uso\_solo\_U*, *Uso\_solo\_R* e *N\_faixas* como variáveis menos importantes para *NASV* e *NACV* e, *Div\_pista\_B*, *Div\_pista\_C* e *N\_faixas* como as menos importantes para ocorrência de acidentes com mortes.



**Figura 6.32** – Fatores de importância dos modelos selecionados da Pista Sul

Em todas as situações nota-se que o volume de tráfego, embora principal preditor, tem menor importância para acidentes com mortes do que para os outros dois tipos de acidentes. Isso implica que a previsão de *NACM* resulta das pequenas contribuições de quase todas as variáveis.

No caso dos acidentes sem vítimas e com vítimas, especialmente no período 2011-2014, o *VDMA* sozinho tem mais de 50% de importância. Nota-se, entretanto, que do período 2011-2014 para o período 2015-2018 houve queda de importância relativa do volume de tráfego para a previsão de acidentes sem vítimas, em ambas as pistas. Isso possivelmente está associado a redução no número de registro de acidentes sem vítimas, mesmo sem significativas alterações nos valores das variáveis explicativas, implicando na necessidade de extrair mais informações de outras variáveis para modelar melhor o problema.

Esse método é capaz de identificar a importância individual de cada variável, ou seja, desconsiderando a existência de interação com as outras variáveis explicativas, como a variável em análise contribuiu para a divisão da árvore de decisão, o que em última instância refere-se ao caminho para a previsão da variável resposta.

Os resultados obtidos são consistentes com o entendimento do fenômeno e, de certo modo, convergem para o constatado pelos outros métodos. Como conclusões gerais, tendo em conta tais resultados e os advindos do método de Morris e método de Sobol', conclui-se que as variáveis menos influentes na ocorrência de acidentes são de uso do solo (*Uso\_solo\_U* e *Uso\_solo\_R*) e ainda, o volume de tráfego é apontado como o fator mais importante.

#### (v) Considerações Finais

Quatro diferentes métodos foram empregados para avaliar a validade estrutural dos modelos de RNA. Conforme Saltelli *et al.* (2004), é comum que diferentes métodos apresentem diferentes resultados para medidas de importância, ou seja, é comum que apresentem diferentes classificações de importância para variáveis de entrada de um modelo. Ainda assim, por todos os métodos empregados (Sobol', Morris, perfil de sensibilidade e fator de importância) houve convergência de constatações em termos de comportamento das variáveis e ainda, de forma conclusiva, a indicação das variáveis menos influentes e de uma nitidamente importante. Refere-se também que as constatações de cada método acerca do comportamento das variáveis para cada nível de severidade são convergentes, não sendo notada expressiva mudança dos fatores contribuintes para os diferentes tipos de acidentes. A síntese dos resultados de cada método está apresentada no Quadro 6.1 e 6.2 para Pista Norte e Pista Sul, respectivamente.

**Quadro 6.1 – Síntese dos resultados da análise de sensibilidade dos modelos de RNA para Pista Norte**

Modelo	PN_3,5km_2011_2014			PN_3,5km_2015_2018		
Método/Variável	NASV	NACV	NACM	NASV	NACV	NACM
Sobol'	<b>Variáveis mais influentes:</b> <i>IRH</i> (maior interação com <i>N_faixas</i> , <i>VDMA</i> e <i>CEV</i> ); <i>L_acost</i> (maior interação com <i>VDMA</i> , <i>IRH</i> e <i>P_ilum</i> ); <i>V_max</i> (maior interação com <i>CEV</i> , <i>P_ilum</i> e <i>VDMA</i> ); <i>P_ilum</i> (maior interação com <i>V_max</i> , <i>N_faixas</i> e <i>CEV</i> ); <i>IMA</i> (maior interação com <i>VDMA</i> e <i>V_max</i> )	<b>Variáveis mais influentes:</b> <i>IRH</i> (maior interação com <i>N_faixas</i> , <i>CEV</i> e <i>P_ilum</i> ); <i>L_acost</i> (maior interação com <i>VDMA</i> , <i>P_ilum</i> e <i>N_faixas</i> ); <i>V_max</i> (maior interação com <i>CEV</i> , <i>P_ilum</i> e <i>VDMA</i> ); <i>P_ilum</i> (maior interação com <i>V_max</i> , <i>N_faixas</i> e <i>CEV</i> ); <i>IMA</i> (maior interação com <i>VDMA</i> e <i>V_max</i> )	<b>Variáveis mais influentes:</b> <i>IRH</i> (maior interação com <i>V_max</i> , <i>PCC</i> e <i>P_ilum</i> ); <i>P_ilum</i> (maior interação com <i>V_max</i> , <i>N_faixas</i> e <i>IRH</i> ); <i>L_acost</i> (maior interação com <i>VDMA</i> , <i>IRH</i> e <i>L_cant</i> ); <i>VDMA</i> (maior interação com <i>N_saídas</i> , <i>PCC</i> , <i>V_max</i> e <i>L_acost</i> ); <i>PCC</i> (maior interação com <i>IRH</i> , <i>VDMA</i> e <i>N_saídas</i> )	<b>Variáveis mais influentes:</b> <i>VDMA</i> (maior interação com <i>IRH</i> , <i>N_faixas</i> e <i>L_acost</i> ); <i>IRH</i> (maior interação com <i>VDMA</i> , <i>L_acost</i> e <i>PCR</i> ); <i>L_acost</i> (maior interação com <i>N_faixas</i> , <i>IRH</i> e <i>V_max</i> ); <i>N_faixas</i> (maior interação com <i>L_acost</i> e <i>VDMA</i> ); <i>L_cant</i> (maior interação com <i>L_acost</i> e <i>VDMA</i> )	<b>Variáveis mais influentes:</b> <i>VDMA</i> (maior interação com <i>IRH</i> , <i>N_faixas</i> e <i>P_ilum</i> ); <i>N_faixas</i> (maior interação com <i>PCR</i> , <i>IMA</i> e <i>VDMA</i> ); <i>IRH</i> (maior interação com <i>VDMA</i> , <i>PCR</i> e <i>L_acost</i> ); <i>L_acost</i> (maior interação com <i>VDMA</i> , <i>IRH</i> e <i>PCR</i> ); <i>PCR</i> (maior interação com <i>N_faixas</i> , <i>P_ilum</i> e <i>IRH</i> )	<b>Variáveis mais influentes:</b> <i>VDMA</i> (maior interação com <i>IRH</i> , <i>N_faixas</i> e <i>L_cant</i> ); <i>L_acost</i> (maior interação com <i>N_faixas</i> , <i>L_cant</i> e <i>P_ilum</i> ); <i>L_cant</i> (maior interação com <i>VDMA</i> , <i>L_acost</i> e <i>IRH</i> ); <i>V_max</i> (maior interação com <i>IRH</i> , <i>N_faixas</i> e <i>IMD</i> ); <i>N_faixas</i> (maior interação com <i>VDMA</i> , <i>L_acost</i> e <i>V_max</i> )
Morris	<b>Variáveis mais influentes:</b> <i>IRH</i> , <i>V_max</i> , <i>L_acost</i> , <i>P_ilum</i> e <i>IMD</i> <b>Variáveis menos influentes:</b> <i>Uso_solo_R</i> , <i>VDMA</i> e <i>Uso_solo_U</i>	<b>Variáveis mais influentes:</b> <i>IRH</i> , <i>V_max</i> , <i>L_acost</i> , <i>P_ilum</i> e <i>PCR</i> <b>Variáveis menos influentes:</b> <i>Uso_solo_R</i> , <i>VDMA</i> e <i>Uso_solo_U</i>	<b>Variáveis mais influentes:</b> <i>IRH</i> , <i>P_ilum</i> , <i>L_acost</i> , <i>PCR</i> e <i>V_max</i> <b>Variáveis menos influentes:</b> <i>Uso_solo_R</i> , <i>VDMA</i> e <i>Uso_solo_U</i>	<b>Variáveis mais influentes:</b> <i>IRH</i> , <i>N_faixas</i> , <i>PCR</i> , <i>L_acost</i> e <i>V_max</i> <b>Variáveis menos influentes:</b> <i>Div_pista_B</i> , <i>VDMA</i> e <i>Uso_solo_U</i>	<b>Variáveis mais influentes:</b> <i>V_max</i> , <i>N_faixas</i> , <i>IRH</i> , <i>PCR</i> e <i>IMA</i> <b>Variáveis menos influentes:</b> <i>Div_pista_B</i> , <i>VDMA</i> e <i>Uso_solo_U</i>	<b>Variáveis mais influentes:</b> <i>L_acost</i> , <i>IRH</i> , <i>L_cant</i> , <i>P_ilum</i> e <i>N_faixas</i> <b>Variáveis menos influentes:</b> <i>Div_pista_B</i> , <i>VDMA</i> e <i>Uso_solo_U</i>
Perfil de sensibilidade	Valores negativos de previsão de acidentes especialmente nos perfis das variáveis: <i>N_aceessos</i> , <i>N_saídas</i> , <i>QI</i> e <i>V_max</i>	Valores negativos de previsão de acidentes especialmente nos perfis das variáveis: <i>CEV</i> , <i>N_aceessos</i> , <i>N_saídas</i> , <i>QI</i> e <i>V_max</i>	Perfil inconclusivo, sem importantes variações	Valores negativos de previsão de acidentes especialmente nos perfis das variáveis: <i>Div_pista_C</i> , <i>N_aceessos</i> , <i>N_faixas</i> e <i>Uso_solo_U</i>	Valores negativos de previsão de acidentes especialmente nos perfis das variáveis: <i>Div_pista_C</i> e <i>IRH</i>	Perfil inconclusivo, sem importantes variações
Fator de importância	<b>Variáveis mais importantes:</b> <i>VDMA</i> , <i>IRH</i> , <i>V_max</i> , <i>L_acost</i> e <i>IMD</i> <b>Variáveis menos importantes:</b> <i>Uso_solo_U</i> , <i>Uso_solo_R</i> e <i>N_faixas</i>	<b>Variáveis mais importantes:</b> <i>VDMA</i> , <i>IRH</i> , <i>IMD</i> , <i>L_acost</i> e <i>QI</i> <b>Variáveis menos importantes:</b> <i>P_ilum</i> , <i>Uso_solo_U</i> e <i>Uso_solo_R</i>	<b>Variáveis mais importantes:</b> <i>VDMA</i> , <i>IMD</i> , <i>IMA</i> , <i>QI</i> e <i>IRH</i> <b>Variáveis menos importantes:</b> <i>Div_pista_C</i> , <i>Div_pista_B</i> e <i>N_faixas</i>	<b>Variáveis mais importantes:</b> <i>VDMA</i> , <i>IRH</i> , <i>V_max</i> , <i>IMD</i> e <i>N_aceessos</i> <b>Variáveis menos importantes:</b> <i>N_faixas</i> , <i>Uso_solo_U</i> e <i>Uso_solo_R</i>	<b>Variáveis mais importantes:</b> <i>VDMA</i> , <i>IRH</i> , <i>QI</i> , <i>IMD</i> e <i>L_acost</i> <b>Variáveis menos importantes:</b> <i>N_faixas</i> , <i>Uso_solo_U</i> e <i>Uso_solo_R</i>	<b>Variáveis mais importantes:</b> <i>VDMA</i> , <i>QI</i> , <i>L_acost</i> , <i>IMA</i> e <i>IMD</i> <b>Variáveis menos importantes:</b> <i>Div_pista_B</i> , <i>Div_pista_C</i> e <i>N_faixas</i>

**Quadro 6.2 – Síntese dos resultados da análise de sensibilidade dos modelos de RNA para Pista Sul**

Modelo	PS_4km_2011_2014			PS_4km_2015_2018		
	NASV	NACV	NACM	NASV	NACV	NACM
Sobol'	<p><b>Variáveis mais influentes:</b> VDMA (maior interação com IMA, IMD, QI, PCC, PCR, L_cant e IRH); PCR (maior interação com VDMA, L_cant e PCC); P_illum (maior interação com VDMA, IMD e L_cant); L_cant (maior interação com VDMA, PCC e IRH); IRH (maior interação com VDMA, L_cant e PCC)</p>	<p><b>Variáveis mais influentes:</b> VDMA (maior interação com L_cant, N_faixas e IRH); P_illum (maior interação com L_cant); PCR (maior interação com L_cant); L_cant (maior interação com PCR, VDMA, PCC e IRH); IRH (maior interação com VDMA e L_cant)</p>	<p><b>Variáveis mais influentes:</b> VDMA (maior interação com IRH, PCC, L_cant, N_faixas e IMD); PCR (maior interação com VDMA, L_cant e IMD); P_illum (maior interação com VDMA, L_cant e IMD); IMD (maior interação com P_illum, VDMA e L_cant); IRH (maior interação com VDMA)</p>	<p><b>Variáveis mais influentes:</b> N_saídas (maior interação com IRH, L_cant e P_illum); N_acessos (maior interação com L_acost, VDMA e IRH); IRH (maior interação com N_saídas, L_cant e N_acessos); P_illum (maior interação com VDMA, N_saídas, IMA e L_cant); VDMA (maior interação com IMD, IMA, L_acost, N_acessos e P_illum)</p>	<p><b>Variáveis mais influentes:</b> N_saídas (maior interação com L_cant, P_illum, IRH e N_acessos); N_acessos (maior interação com L_acost, N_saídas e L_cant); VDMA (maior interação com L_cant, N_acessos e P_illum); P_illum (maior interação com N_saídas, L_cant, IMA e IMD); L_acost (maior interação com N_acessos e IMD)</p>	<p><b>Variáveis mais influentes:</b> N_saídas (maior interação com P_illum, L_cant e IRH); N_acessos (maior interação com N_saídas, L_acost, VDMA e IMD); VDMA (maior interação com N_acessos, L_acost e IMD); L_acost (maior interação com N_acessos, N_saídas e VDMA); P_illum (maior interação com N_saídas e IMD)</p>
Morris	<p><b>Variáveis mais influentes:</b> PCR, L_cant, P_illum, IMA e IRH <b>Variáveis menos influentes:</b> Uso_solo_R, VDMA e Uso_solo_U</p>	<p><b>Variáveis mais influentes:</b> L_cant, P_illum, PCR, IRH e IMA <b>Variáveis menos influentes:</b> Uso_Solo_R, VDMA e Uso_solo_U</p>	<p><b>Variáveis mais influentes:</b> PCR, P_illum, IRH, N_faixas e IMD <b>Variáveis menos influentes:</b> Div_pista_C, VDMA e Uso_solo_U</p>	<p><b>Variáveis mais influentes:</b> N_saídas, N_acessos, IMA, P_illum e IRH <b>Variáveis menos influentes:</b> Div_pista_C, VDMA e Uso_solo_U</p>	<p><b>Variáveis mais influentes:</b> N_acessos, N_saídas, P_illum, IMA e L_cant <b>Variáveis menos influentes:</b> Div_pista_C, VDMA e Uso_solo_U</p>	<p><b>Variáveis mais influentes:</b> N_saídas, N_acessos, IMA, L_acost e P_illum <b>Variáveis menos influentes:</b> Div_pista_C, VDMA e Uso_solo_U</p>
Perfil de sensibilidade	Valores negativos de previsão de acidentes especialmente nos perfis das variáveis: Div_pista_C, IMA, IMD, L_acost, N_acessos, N_saídas, PCC, PCR, QI e V_max	Valores negativos de previsão de acidentes especialmente nos perfis das variáveis: IMA, IMD, L_cant, N_acessos, N_faixas, N_saídas e VDMA	Perfil inconclusivo, sem importantes variações	Valores negativos de previsão de acidentes especialmente nos perfis das variáveis: CEV, IRH, L_acost, L_cant, N_faixas, PCC e V_max	Escala de variação dos perfis incompatível com a escala dos valores observados de acidentes	Perfil inconclusivo, sem importantes variações
Fator de importância	<p><b>Variáveis mais importantes:</b> VDMA, L_acost, QI, IMA e IRH <b>Variáveis menos importantes:</b> N_faixas, Uso_solo_U e Uso_solo_R</p>	<p><b>Variáveis mais importantes:</b> VDMA, IMD, IRH, IMA e L_acost <b>Variáveis menos importantes:</b> N_faixas, Uso_solo_R e Uso_solo_U</p>	<p><b>Variáveis mais importantes:</b> VDMA, IMA, IMD, QI e L_acost <b>Variáveis menos importantes:</b> Uso_solo_R, Div_pista_B e Div_pista_C</p>	<p><b>Variáveis mais importantes:</b> VDMA, IRH, CEV, L_acost e IMA <b>Variáveis menos importantes:</b> Div_pista_C, Uso_solo_U e Uso_solo_R</p>	<p><b>Variáveis mais importantes:</b> VDMA, QI, IMD, L_acost e IMA <b>Variáveis menos importantes:</b> P_illum, Uso_solo_U e Uso_solo_R</p>	<p><b>Variáveis mais importantes:</b> VDMA, QI, L_acost, IMA e IMD <b>Variáveis menos importantes:</b> N_faixas, Div_pista_C e Div_pista_B</p>

Cada método contribuiu para o entendimento parcial do comportamento das variáveis explanatórias podendo-se concluir que essas possuem indicativo de comportamento não linear com as variáveis resposta e de interação com as demais variáveis explicativas. E mais, revelam o uso do solo como um fator pouco influente para a ocorrência de acidentes e apontam o volume de tráfego como um fator importante. Os demais apontamentos acerca da influência das variáveis não são consensuais entre os métodos e, portanto, devem ser tratados com cautela.

Ainda assim, acredita-se, a partir dos resultados, que no contexto geral o *IRH* também pode ser tido como um fator importante. O método de perfil de sensibilidade não se mostrou muito profícuo, dadas as interações entre as variáveis explicativas e forma de funcionamento do método frente as características de algumas variáveis. Os métodos de análise de sensibilidade podem ser úteis, mas devem ser empregados com cautela por dependerem não somente do problema modelado, mas das amostras utilizadas, do procedimento de execução e das características da rede neural. Posto isto, embora sem muitas conclusões práticas acerca de como cada variável influencia em cada variável resposta, entende-se que os modelos apresentados apresentam validade estrutural parcial.

### **6.3.2. Coeficientes Estimados dos Modelos MVPLN**

Apesar de pouco comum aos modelos estatísticos, pode-se encarar a análise dos coeficientes estimados como uma forma de validar estruturalmente o modelo desenvolvido. Nas Tabelas 6.14 e 6.15 estão apresentados os resultados para os modelos selecionados. Os valores negritos referem-se aos coeficientes estatisticamente significativos a um nível de significância de 5%. Os sinais dos coeficientes indicam a direção do efeito de cada variável de entrada. As magnitudes desses coeficientes, no entanto, não são diretamente comparáveis como de outros modelos. Assim, para avaliar o impacto relativo de cada variável no modelo, utiliza-se a elasticidade, cujos valores também estão apresentados nas tabelas.

**Tabela 6. 14 – Coeficientes estimados dos modelos MVPLN selecionados para Pista Norte**

Variável	PN_3,5km_2011_2014									PN_3,5km_2015_2018								
	Acidentes sem vítimas			Acidentes com vítimas			Acidentes com mortes			Acidentes sem vítimas			Acidentes com vítimas			Acidentes com mortes		
	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.
Constante	<b>-42,820</b>	<b>7,406</b>		<b>-21,020</b>	<b>7,047</b>		-9,914	14,630		<b>-23,740</b>	<b>14,520</b>		<b>-16,760</b>	<b>5,188</b>		-19,050	11,300	
log(VDMA)	-0,806	0,637	-3,479	0,164	0,587	0,709	<b>-1,209</b>	<b>0,712</b>	<b>-5,217</b>	<b>0,316</b>	<b>0,203</b>	<b>1,365</b>	<b>0,703</b>	<b>0,311</b>	<b>3,030</b>	0,552	0,387	2,381
IMA	<b>4,857</b>	<b>2,615</b>	<b>6,879</b>	<b>2,673</b>	<b>2,281</b>	<b>3,786</b>	2,451	2,568	3,471	1,324	0,922	1,875	0,738	0,720	1,046	0,137	0,291	0,194
IMD	-0,260	0,611	-0,430	-0,184	0,386	-0,305	-0,051	0,420	-0,085	0,746	0,668	1,235	0,589	0,470	0,975	0,026	0,233	0,044
L_acost	<b>1,219</b>	<b>0,660</b>	<b>2,031</b>	<b>0,650</b>	<b>0,513</b>	<b>1,082</b>	0,633	0,606	1,054	1,213	0,778	2,021	0,912	0,767	1,520	-0,164	0,430	-0,273
L_cant	-0,269	0,151	-0,603	<b>-0,146</b>	<b>0,103</b>	<b>-0,327</b>	<b>-0,244</b>	<b>0,129</b>	<b>-0,547</b>	0,179	0,243	0,401	0,166	0,222	0,373	-0,066	0,112	-0,147
N_faixas	<b>2,255</b>	<b>1,194</b>	<b>4,623*</b>	<b>1,244</b>	<b>0,981</b>	<b>2,550*</b>	0,859	1,266	1,760*	<b>2,563</b>	<b>1,426</b>	<b>5,254*</b>	1,846	1,510	3,784*	-0,343	0,982	-0,704*
N_acessos	<b>3,683</b>	<b>1,127</b>	<b>7,292*</b>	<b>1,843</b>	<b>1,174</b>	<b>3,649*</b>	<b>1,939</b>	<b>1,284</b>	<b>3,839*</b>	-0,491	0,408	-0,972*	-0,338	0,338	-0,668*	-0,315	0,204	-0,624*
N_saídas	0,662	0,455	1,377*	0,273	0,334	0,568*	0,234	0,398	0,487*	0,259	0,597	0,540*	0,310	0,527	0,644*	0,258	0,251	0,536*
PCC	-3,721	2,796	-0,939	-9,605	6,725	-2,424	5,939	9,767	1,499	<b>-6,418</b>	<b>3,391</b>	<b>-1,620</b>	<b>-12,390</b>	<b>7,955</b>	<b>-3,127</b>	-7,361	8,521	-1,857
PCR	0,653	1,285	0,488	-7,467	5,690	-5,583	6,899	9,951	5,158	-1,190	1,904	-0,890	<b>-8,583</b>	<b>5,030</b>	<b>-6,417</b>	-6,957	8,732	-5,201
log(IRH)	-0,339	0,221	1,147	-0,160	0,159	0,541	-0,246	0,179	0,830	0,147	0,128	-0,497	0,097	0,100	-0,326	0,056	0,099	-0,189
V_max	0,001	0,013	0,117	0,000	0,010	-0,026	0,011	0,015	1,129	-0,010	0,014	-1,014	0,000	0,012	0,045	0,004	0,013	0,408
P_ilum	<b>-17,370</b>	<b>8,915</b>	<b>-0,600</b>	<b>-6,728</b>	<b>4,301</b>	<b>-0,232</b>	-6,639	4,535	-0,229	-0,355	8,915	-0,012	1,196	6,327	0,041	-2,198	1,890	-0,076
CEV	-2,161	2,018	-0,605*	-0,328	0,753	-0,092*	-0,148	0,829	-0,041*	0,411	0,778	0,115*	0,311	0,633	0,087*	0,463	0,303	0,130*
QI	-0,026	0,068	-0,755	-0,010	0,051	-0,286	-0,008	0,072	-0,216	<b>0,058</b>	<b>0,017</b>	<b>1,546</b>	<b>0,064</b>	<b>0,020</b>	<b>1,703</b>	0,059	0,071	1,566
Div_pista_B	1,033	2,521	-	-0,900	1,686	-	-12,910	18,510	-	<b>9,869</b>	<b>2,148</b>	-	9,675	5,756	-	15,660	11,910	-
Div_pista_C	-0,095	2,086	-	-0,577	1,673	-	-11,620	18,280	-	1,376	5,164	-	4,123	7,787	-	16,630	12,640	-
Uso_solo_R	<b>21,050</b>	<b>7,868</b>	-	<b>14,460</b>	<b>7,786</b>	-	9,757	11,640	-	2,632	8,836	-	1,508	4,407	-	2,338	8,631	-
Uso_solo_U	<b>-3,043</b>	<b>1,564</b>	-	5,954	4,597	-	1,972	10,210	-	<b>-5,333</b>	<b>2,643</b>	-	-2,154	2,291	-	3,349	8,828	-

**Nota:** DP é o desvio padrão; Elast. é a elasticidade; Os valores em negrito referem-se aos coeficientes estatisticamente significativos a um nível de significância de 5%; As quatro últimas variáveis são indicadores binários, não sendo aplicável a elasticidade; Variáveis discretas de valores inteiros têm apenas referidos os valores computados de elasticidade (assinalados com \*), embora não sendo diretamente aplicável a elasticidade.



**Tabela 6. 15** – Coeficientes estimados dos modelos MVPLN selecionados para Pista Sul

Variável	PS_4km_2011_2014									PS_4km_2015_2018								
	Acidentes sem vítimas			Acidentes com vítimas			Acidentes com mortes			Acidentes sem vítimas			Acidentes com vítimas			Acidentes com mortes		
	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.
Constante	<b>-85,530</b>	<b>3,815</b>		<b>-23,010</b>	<b>6,455</b>		-6,579	11,760		<b>29,180</b>	<b>9,909</b>		<b>-15,220</b>	<b>6,420</b>		4,025	8,510	
log(VDMA)	<b>-0,547</b>	<b>0,422</b>	<b>-2,367</b>	<b>0,719</b>	<b>0,167</b>	<b>3,110</b>	0,224	0,316	0,968	0,407	0,248	1,758	<b>0,686</b>	<b>0,223</b>	<b>2,964</b>	0,681	0,385	2,942
IMA	<b>3,391</b>	<b>1,246</b>	<b>5,617</b>	<b>0,749</b>	<b>0,372</b>	<b>1,241</b>	0,139	0,290	0,231	0,389	0,571	0,645	0,255	0,321	0,422	0,226	0,310	0,374
IMD	-0,144	0,697	-0,217	-0,077	0,126	-0,116	-0,048	0,146	-0,072	-0,215	0,930	-0,323	0,059	0,334	0,089	-0,131	0,329	-0,197
L_acost	<b>2,852</b>	<b>1,005</b>	<b>4,611</b>	<b>0,696</b>	<b>0,260</b>	<b>1,126</b>	0,114	0,318	0,184	-0,014	0,800	-0,023	0,212	0,475	0,343	0,128	0,498	0,207
L_cant	0,683	0,231	1,434	0,106	0,092	0,223	0,105	0,103	0,220	0,543	0,511	1,140	0,269	0,366	0,564	0,031	0,298	0,065
N_faixas	0,770	0,907	1,558*	0,362	0,345	0,733*	0,004	0,736	0,008*	<b>0,996</b>	<b>0,673</b>	<b>2,015*</b>	0,606	0,523	1,227*	-0,696	1,565	-1,408*
N_acessos	<b>3,044</b>	<b>0,698</b>	<b>7,383*</b>	<b>0,582</b>	<b>0,289</b>	<b>1,411*</b>	0,128	0,315	0,310*	0,734	0,655	1,779*	0,439	0,489	1,064*	0,121	0,411	0,294*
N_saídas	-0,547	0,501	-1,408*	-0,026	0,100	-0,066*	0,051	0,143	0,132*	0,008	0,222	0,020*	0,043	0,153	0,112*	0,290	0,190	0,746*
PCC	<b>12,860</b>	<b>3,822</b>	<b>3,242</b>	-2,745	2,798	-0,692	15,950	12,370	4,021	2,768	9,022	0,698	-0,703	3,640	-0,177	-9,297	10,820	-2,343
PCR	2,768	2,865	2,070	-4,789	3,516	-3,582	15,260	11,770	11,413	-0,897	4,345	-0,671	-1,062	1,684	-0,794	-9,010	9,941	-6,739
log(IRH)	<b>1,110</b>	<b>0,286</b>	<b>-3,790</b>	<b>0,246</b>	<b>0,121</b>	<b>-0,840</b>	0,071	0,139	-0,242	-0,016	0,165	0,055	0,054	0,107	-0,183	0,120	0,133	-0,408
V_max	<b>-0,039</b>	<b>0,010</b>	<b>-3,970</b>	<b>-0,011</b>	<b>0,005</b>	<b>-1,141</b>	-0,012	0,012	-1,208	-0,025	0,016	-2,524	-0,009	0,008	-0,899	<b>-0,031</b>	<b>0,015</b>	<b>-3,129</b>
P_ilum	<b>67,670</b>	<b>24,810</b>	<b>1,860</b>	<b>10,870</b>	<b>5,151</b>	<b>0,299</b>	-0,905	4,068	-0,025	-4,639	9,684	-0,128	-1,019	4,430	-0,028	-1,568	4,081	-0,043
CEV	<b>-6,447</b>	<b>2,819</b>	<b>-1,556*</b>	-1,114	0,855	-0,269*	-0,135	0,650	-0,033*	-5,574	5,392	-1,345*	-2,901	3,785	-0,700*	-2,335	2,990	-0,564*
QI	<b>0,089</b>	<b>0,042</b>	<b>2,488</b>	<b>0,042</b>	<b>0,020</b>	<b>1,166</b>	0,071	0,059	1,985	<b>0,082</b>	<b>0,012</b>	<b>2,175</b>	<b>0,042</b>	<b>0,017</b>	<b>1,118</b>	0,056	0,092	1,489
Div_pista_B	<b>0,361</b>	<b>1,154</b>	-	2,739	2,261	-	-3,944	11,970	-	11,530	8,036	-	3,846	3,590	-	-1,559	12,320	-
Div_pista_C	<b>9,976</b>	<b>4,442</b>	-	5,239	3,305	-	-2,998	12,090	-	<b>16,370</b>	<b>3,337</b>	-	5,222	2,898	-	0,423	11,570	-
Uso_solo_R	<b>52,790</b>	<b>4,471</b>	-	<b>12,300</b>	<b>6,424</b>	-	-10,610	8,949	-	0,833	2,276	-	1,448	4,697	-	-1,134	7,730	-
Uso_solo_U	0,796	1,320	-	2,659	2,149	-	-13,780	11,480	-	-1,588	1,936	-	0,279	3,470	-	-1,961	7,357	-

**Nota:** DP é o desvio padrão; Elast. é a elasticidade; Os valores em negrito referem-se aos coeficientes estatisticamente significativos a um nível de significância de 5%; As quatro últimas variáveis são indicadores binários, não sendo aplicável a elasticidade; Variáveis discretas de valores inteiros têm apenas referidos os valores computados de elasticidade (assinalados com \*), embora não sendo diretamente aplicável a elasticidade.

No modelo PN\_3,5km\_2011\_2014, apenas as variáveis *VDMA*, *IMA*, *L\_acost*, *L\_cant*, *N\_faixas*, *N\_acessos*, *P\_ilum*, *Uso\_solo\_U* e *Uso\_solo\_R* tiveram coeficientes estatisticamente significativos em pelo menos um nível de severidade, sendo apenas *N\_acessos* significativos em todos os níveis. No período posterior, o outro modelo da Pista Norte tem um conjunto ainda menor de variáveis significativas, são elas: *VDMA*, *N\_faixas*, *PCC*, *PCR*, *QI*, *Div\_pista\_B* e *Uso\_solo\_U*. Apenas o volume de tráfego, número de faixas e uso do solo urbano mantiveram-se como significativas em ambos modelos. No caso da Pista Sul, para o modelo PS\_4km\_2011\_2014, apenas *IMD*, *L\_cant*, *N\_faixas*, *N\_saídas*, *PCR* e *Uso\_solo\_U* não foram significativas enquanto que, no sentido contrário, para o modelo PS\_4km\_2015\_2018 somente as variáveis *VDMA*, *N\_faixas*, *V\_max*, *QI* e *Div\_pista\_C* se mostraram significativas. E ainda, tanto para o segundo modelo da Pista Norte como para o primeiro modelo da Pista Sul, nenhum coeficiente foi estatisticamente significativo para acidentes com mortes.

Centrando a análise em termos dos coeficientes significativos, observa-se que o logaritmo do volume de tráfego está negativamente associado a ocorrência de acidentes com mortes para a Pista Norte no período 2011-2014 assim como para ocorrência de acidentes sem vítimas no modelo PS\_4km\_2011\_2014. Doutro lado, está positivamente associado aos acidentes sem vítimas e com vítimas do modelo PN\_3,5km\_2015\_2018 e aos acidentes com vítimas dos modelos da Pista Sul. A elasticidade média do número esperado de acidentes sugere, por exemplo, que um aumento de 1% no logaritmo de *VDMA* implica num aumento de 1,37% dos acidentes sem vítimas e de 3,03% nos acidentes com vítimas, para a Pista Norte, no período de 2015 a 2018.

Assim como para o volume de tráfego, em outras variáveis também se verifica ora associação positiva à ocorrência de acidentes, ora associação negativa. Em contrapartida, também são observadas variáveis que tem comportamento convergente em todos os casos. Na Tabela 6.16 estão sumarizadas as relações dos coeficientes significativos e cada nível de severidade para cada modelo. As células em branco representam as variáveis não significativas para determinado nível de severidade, “+” representa uma associação positiva entre a variável e a ocorrência do respectivo tipo de acidente e, “-” representa uma associação negativa.

Algumas considerações são apresentadas na sequência. A inclinação média ascendente (*IMA*) do perfil da rodovia foi apontada em todos os casos como positivamente associada aos acidentes sem vítimas e com vítimas. Essa constatação converge com as obtidas por outros trabalhos

como Hossein e Arabani (2012), Bauer e Harwood (2014) e Sameen e Pradhan (2017), sendo razoável por estar associada a redução de visibilidade do condutor (Glennon, 1987).

A largura do acostamento ( $L_{acost}$ ) foi verificada como tendo associação positiva com a ocorrência de acidentes sem vítimas e com vítimas, em todos os casos que foi estatisticamente significativa. Tradicionalmente, os achados da literatura são no sentido contrário constatando-se a redução do número de acidentes com o aumento da largura do acostamento, inclusive sendo proposta como uma contramedida de segurança viária (ZEGEER *et al.*, 1992; STAMATIADIS *et al.*, 2009; BAMZAI *et al.*, 2011; BOODLAL *et al.*, 2015). Entretanto, recentemente Gitelman *et al.* (2019) constataram no estudo conduzido por eles que, há aumento do risco de acidentes de todos os tipos para largura de acostamento de até 2,2 m e, uma consequentemente diminuição nos acidentes para largura superiores a esse valor. Isso pode justificar, em alguma medida, o resultado constatado no presente estudo, tendo em conta que o valor médio da largura de acostamento é de 1,65 m para a Pista Norte e 1,59 m para Pista Sul.

**Tabela 6. 16 -** Relacionamento das variáveis com cada tipo de acidente

Variável	PN_3,5km_2011_2014			PN_3,5km_2015_2018			PS_4km_2011_2014			PS_4km_2015_2018		
	ASV	ACV	ACM	ASV	ACV	ACM	ASV	ACV	ACM	ASV	ACV	ACM
<i>VDMA</i>			-	+	+		-	+			+	
<i>IMA</i>	+	+					+	+				
<i>L_acost</i>	+	+					+	+				
<i>L_cant</i>		-	-									
<i>N_faixas</i>	+	+		+							+	
<i>N_aceessos</i>	+	+	+				+	+				
<i>PCC</i>				-	-		+					
<i>PCR</i>					-							
<i>IRH</i>							-	-				
<i>V_max</i>							-	-				-
<i>P_ilum</i>	-	-					+	+				
<i>CEV</i>							-					
<i>QI</i>				+	+		+	+		+	+	
<i>Div_pista_B</i>				+			+					
<i>Div_pista_C</i>							+			+		
<i>Uso_solo_R</i>	+	+					+	+				
<i>Uso_solo_U</i>	-			-								

**Nota:** ASV – acidente sem vítimas; ACV – acidente com vítimas; ACM – acidentes com vítimas.

A largura do canteiro ( $L_{cant}$ ) apresentou um relacionamento negativo com a ocorrência de acidentes com vítimas e com mortes, o que significa dizer que é razoável esperar que o aumento da largura de canteiro central implique na redução desses tipos de acidente, como verificado por Davis (2008), Stamatiadis *et al.* (2009) e FDOT (2014). Essa constatação é esperada, já que quanto maior a separação física entre as pistas, menor o risco de colisão, especialmente frontal, entre veículos.

Com o aumento do número de faixas ( $N_{faixas}$ ) é de se esperar que haja aumento no número de acidentes sem vítimas e com vítimas. Isso também foi constatado por Kononov *et al.* (2008) e Wang *et al.* (2011), tendo-se como possível explicação o aumento das chances de conflitos relacionados à mudança de faixa, em decorrência da existência de mais faixas.

O número de acessos ( $N_{acessos}$ ) está positivamente relacionado à ocorrência de todos os tipos de acidente. Esse comportamento já era esperado e é referido por diversos autores tais como McCartt *et al.* (2004), Cerezo e Conche (2016), Qu *et al.* (2014) e Hu *et al.* (2017).

A Proporção de Comprimento de Reta ( $PCR$ ) no segmento foi significativa apenas para uma situação de acidente com vítima, com relação negativa. Espera-se, portanto, que o aumento da proporção de tangente no segmento implicará na redução do número desse tipo de acidente. Tendo em conta as afirmações de Neumann *et al.* (1983), Zegeer *et al.* (1992), Ratanavaraha e Suangka (2014) e Bíl *et al.* (2019), que afirmam haver maior risco de acidentes em trechos curvos, essa constatação é bastante razoável.

O Inverso do raio de curva horizontal ( $IRH$ ) apresenta uma relação negativa com a ocorrência de acidentes sem vítimas e com vítimas, o que não era o esperado. Diversos trabalhos (GLENNON, 1987; VAN DER HORST & RIDDER, 2007; CHEN, 2010; COSTA, 2013; JAMSON *et al.*, 2015; CAFISO *et al.*, 2018) confirmam que curvas com raios menores apresentam maior risco aos acidentes do que curvas com raios maiores.

Ainda assim, Wang *et al.* (2018) também constatou relação negativa entre a curvatura e os acidentes. No caso em tela, uma possível explicação seja a de compensação de risco por parte dos condutores. Explicando melhor, sabendo da existência de trechos muito sinuosos e com altas taxas de acidentes, o motorista altera seu comportamento de condução a fim de manter um nível de risco aceitável, empregando maior cautela nas manobras, o que acaba por culminar na ocorrência de menos acidentes (MANNERING & BATH, 2014).

A velocidade limite regulamentada ( $V_{max}$ ) apresentou relação negativa com a ocorrência de todos os tipos de acidentes. O resultado, embora discordante de muitos trabalhos constantes na literatura, converge para o constatado por Imprialou *et al.* (2016). Os autores constaram que, para acidentes de diferentes severidades a relação entre velocidade e acidentes é negativa, de forma que quanto maiores os patamares de velocidade menores os acidentes ocorridos. De outro lado, a existência de controladores eletrônicos de velocidade (*CEV*), estratégia de fiscalização, também teve associação negativa com o número de acidentes, como de se esperar. Elvik (2011) afirma que esforços que visem o controle de velocidade são desafios para governantes e gestores, mas que repercutem em redução do número de acidentes, o que é reiterado por ITF (2018). Embora pareça contraditório, esses resultados apontam para menor ocorrência de acidentes em trechos com velocidades mais altas, com efeito complementado pela existência de dispositivos de fiscalização que busquem assegurar o respeito à velocidade regulamentada do trecho.

O quociente de irregularidade do pavimento foi tido como positivamente associado com os acidentes sem vítimas e com vítimas em três dos quatro modelos. Tal observação converge para o constatado por Othman *et al.* (2009), os quais afirmam que a degradação das condições de regularidade longitudinal do pavimento provoca o aumento do número de acidentes.

As duas variáveis que se referem ao tipo de divisão de pista (*Div\_pista\_B* e *Div\_pista\_C*) estão positivamente associadas a ocorrência de acidentes. Isso sugere que, tanto com a existência de barreira rígida quanto com a ocorrência de canteiro central, o número de acidentes é incrementado. Embora a constatação geral seja de redução de acidentes frente a implantação de separação física entre as pistas (LABI, 2006; FDOT, 2014), Elvik e Vaa (2004) verificaram a redução do número de acidentes com feridos, mas o aumento do número de acidentes somente com danos materiais, decorrente da implantação de separação de pista em áreas urbanas. Considerando que a maior parte da rodovia analisada no presente estudo está inserida no contexto urbano e que, a associação positiva com os acidentes se deu apenas para acidentes sem vítimas, nota-se convergência de constatação. E, adicionalmente, como já verificado, a largura do canteiro ( $L_{cant}$ ) está associada à redução de acidentes com feridos e mortos, mas não aos acidentes sem vítimas, o que também reforça as constatações acerca do efeito da divisão de pista para a ocorrência dos acidentes.

O tipo de uso do solo rural (*Uso\_Solo\_R*) foi verificado como contribuindo positivamente para a ocorrência de acidentes sem vítimas e com vítimas. Doutro lado, o uso do solo tipo urbano (*Uso\_solo\_U*) está associado negativamente a ocorrência de acidentes sem vítimas. Essas descobertas convergem para o enunciado por Shankar *et al.* (1995), Carson e Mannering (2001) e Musa e Moses (2014), provavelmente devido a diferença de velocidade operacional praticada em áreas urbanas e rurais, culminando em mais acidentes nesse último caso.

Com efeitos menos consistentes, ou seja, ocorrência de efeitos positivo e negativo, a depender do modelo, estão o volume de tráfego, proporção de comprimento de curva no segmento e proporção de iluminação. O volume de tráfego (*VDMA*) está associado positivamente à ocorrência de acidentes sem vítimas e com vítimas em alguns modelos, mas negativamente associado aos acidentes com mortes e sem vítimas em outros. Para acidentes com vítimas a associação com *VDMA* é sempre positiva. Para os outros dois níveis de severidade é indicada redução do número de acidentes com o incremento do volume de tráfego, o que parece contrassenso, mas também constatado por Chang e Xiang (2003) e Wong *et al.* (2007). A redução da velocidade operacional decorrente do aumento do tráfego é uma das possíveis explicações apontadas.

A Proporção de Comprimento de Curva (*PCC*) no segmento foi apontada como tendo tanta relação positiva quanto negativa com os acidentes sem vítimas. Geralmente ocorrem mais acidentes em curvas do que em tangentes (NEUMANN *et al.*, 1983; ZEGEER *et al.*, 1992; RATANAVARAHHA & SUANGKA, 2014), no entanto, isso é devido mais ao raio de curva do que a existência de trecho curvo por si só. Como essa variável tem em conta apenas a extensão de curva proporcional à extensão do segmento, a captura desse efeito pode ser ambígua, como aqui constatado.

Por fim, a proporção de iluminação artificial no segmento (*P\_ilum*) apresentou associação positiva e negativa com a ocorrência de acidentes. ICI (1992), Elvik (1995) e Wanvik (2009) apontam a iluminação como fator importante para redução de acidentes e severidade resultante. A associação positiva constatada para acidentes sem vítimas e com vítimas em um modelo da Pista Sul pode ser resultante da endogeneidade, já que a implantação de iluminação se dá geralmente nos pontos mais críticos da rodovia. Portanto, é possível que o efeito capturado seja dependente da frequência de acidentes nos segmentos e não exatamente da existência dos dispositivos de iluminação.

Ainda se refere que a correlação entre os efeitos latentes dos diferentes níveis de severidade foi quantificada. A correlação entre acidentes sem vítimas e com vítimas foi significativa e alta com valores superiores a 0,9 em todos os casos. Esse comportamento de níveis de severidade adjacentes altamente correlacionados já era esperado, conforme afirma Agüero-Valverde e Jovanis (2009). Além do que, esses resultados aproximam-se dos obtidos por Wang *et al.* (2018).

As correlações entre os outros dois níveis de severidade (acidentes sem vítimas e acidentes com mortes e, acidentes com vítimas e acidentes com mortes) também apresentaram valores relativamente altos. Com exceção do modelo da Pista Norte no período 2015-2018, a correlação ASV-ACM variou de 0,43 a 0,83 e entre ACV-ACM de 0,44 a 0,83. Esse patamar de valores também se alinha com o verificado por Agüero-Valverde e Jovanis (2009) e Zhan *et al.* (2015).

As verificações neste estudo confirmam a suposição de correlação existente entre todos os níveis de severidade, reforçando a necessidade de modelagem de resposta multivariada com ajuste conjunto do modelo para múltiplos níveis de severidade (MA *et al.*, 2008; ZHAN *et al.*, 2015).

- *Seleção de Variáveis*

O conjunto de variáveis utilizado no processo de modelagem foi o mesmo tanto para a abordagem com RNA quanto com MVPLN, o que possibilitou comparação dos resultados, tirando melhor proveito de cada abordagem, já que, para o MVPLN os melhores resultados também foram verificados com o conjunto original de variáveis explicativas. Embora a seleção de variáveis possa ser considerada uma etapa de calibração dos modelos estatísticos, para tornar a comparação com os modelos de RNA mais adequada e também pela necessidade de emprego adaptado do método *backward* (adequado para modelos univariados), essa redução do conjunto de variáveis explanatórias foi encarada como uma investigação do potencial de redução de dimensionalidade mantendo o mesmo patamar de desempenho dos modelos, ainda que os modelos finais, assim como apresentado na literatura, tenham sido os obtidos com o conjunto original de variáveis.

Esse processo, automático para outros modelos estatísticos, aqui é manual, moroso e de grande custo computacional. A cada execução os resultados devem ser investigados para identificação da variável menos significativa e, posteriormente, procedidas as alterações do código computacional, do arquivo de inicialização do modelo e da base de dados para a execução seguinte. Embora seja uma análise exaustiva, pode conduzir a resultados interessantes, como ocorreu. Na Tabela 6.17 estão apresentados os passos executados para a seleção de variáveis em cada um dos modelos selecionados. Todas as variáveis resultantes dos modelos após a seleção também tinham sido apontadas como significativas nos modelos com o conjunto total de variáveis, à exceção de *Div\_pista\_B* para o modelo PN\_3,5km\_2011\_2014.

**Tabela 6.17**– Resultados dos passos executados na seleção backward

	PN_3,5km_2011_2014	PN_3,5km_2015_2018	PS_4km_2011_2014	PS_4km_2015_2018
<b>Passo</b>	<b>Variável eliminada</b>			
1	<i>V_max</i>	<i>V_max</i>	<i>N_saídas</i>	<i>IRH</i>
2	<i>QI</i>	<i>IRH</i>	<i>V_max</i>	<i>V_max</i>
3	<i>IMD</i>	<i>L_cant</i>	<i>L_cant</i>	<i>L_cant</i>
4	<i>L_acost</i>	<i>IMD</i>	<i>L_acost</i>	<i>IMD</i>
5	<i>L_cant</i>	<i>IMA</i>	<i>IRH</i>	<i>IMA</i>
6	<i>N_saídas</i>	<i>N_saídas</i>	<i>IMD</i>	<i>N_saídas</i>
7	<i>IRH</i>	<i>L_acost</i>	<i>N_faixas</i>	<i>N_acessos</i>
8	<i>VDMA</i>	<i>N_acessos</i>	<i>IMA</i>	<i>CEV</i>
9	<i>N_acessos</i>	<i>CEV</i>	<i>PCC</i>	<i>L_acost</i>
10	<i>P_ilum</i>	<i>N_faixas</i>	<i>CEV</i>	<i>N_faixas</i>
11	<i>IMA</i>	<i>PCR</i>	<i>N_acessos</i>	<i>VDMA</i>
12	<i>N_faixas</i>	<i>PCC</i>	<i>PCR</i>	<i>P_ilum</i>
13	<i>PCR</i>	<i>Uso_solo_R</i>	<i>Uso_solo_R</i>	<i>Uso_solo_R</i>
14	<i>PCC</i>	<i>Uso_solo_U</i>	<i>Uso_solo_U</i>	<i>Uso_solo_U</i>
15	<i>Uso_solo_R</i>	<i>P_ilum</i>	<i>Div_pista_C</i>	<i>Div_pista_C</i>
16	<i>CEV</i>	<i>Div_pista_B</i>		<i>Div_pista_B</i>
17	<i>Div_pista_C</i>	<i>Div_pista_C</i>		<i>PCR</i>
18				<i>PCC</i>

Como é de se notar, o conjunto de variáveis original foi reduzido drasticamente, resultando em quatro, duas ou apenas uma variável explicativa, a depender do modelo. Uma explicação possível é que, a seleção de variáveis do tipo *backward*, desenvolvida para modelos de resposta univariada, não são plenamente adequados para emprego em modelos de resposta multivariada. Ademais, observa-se que devido a correlação existente entre os níveis de severidade, algumas variáveis podem ser significativas em modelos multivariados (MVPLN) e não significativas em modelos univariados, e vice-versa (MA *et al.*, 2008; WANG *et al.*, 2018). Isso sugere que a execução da seleção *backward* em modelos de resposta univariada pode resultar num conjunto



de variáveis distinto do obtido a partir de modelos multivariados. Na Tabela 6.18 estão apresentados os coeficientes estimados para os modelos finais após seleção de variáveis.

Cada modelo resultou num conjunto de variáveis explicativas diferente, ainda assim nota-se a presença de *QI* em três dos quatro modelos, sendo inclusive a única variável explicativa do modelo da Pista Sul no período de 2015 a 2018. Quanto aos efeitos das variáveis, o sinal dos coeficientes confirma o que havia sido obtido na modelagem original, excetuando-se a divisão de pista do tipo barreira (*Div\_pista\_B*) que agora passou a ter efeito negativo para os acidentes em um dos modelos, o que corrobora com os principais achados da literatura.

**Tabela 6.18** - Coeficientes estimados para modelos resultantes da seleção de variáveis - MVPLN

Descrição da variável	PN_3,5km_2011_2014								
	Acidentes sem vítimas			Acidentes com vítimas			Acidentes com mortes		
	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.
Constante	<b>-30,77</b>	<b>10,67</b>		<b>-19,09</b>	<b>5,274</b>		<b>-12,03</b>	<b>3,872</b>	
<i>Div_pista_B</i>	<b>11,12</b>	<b>3,008</b>	-	<b>8,03</b>	<b>3,732</b>	-	4,288	2,516	-
<i>Uso_solo_U</i>	<b>-8,779</b>	<b>5,381</b>	-	<b>-6,795</b>	<b>5,452</b>	-	-3,793	3,605	-
Descrição da variável	PN_3,5km_2015_2018								
	Acidentes sem vítimas			Acidentes com vítimas			Acidentes com mortes		
	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.
Constante	<b>-21,21</b>	<b>11,99</b>		<b>-17,75</b>	<b>5,307</b>		<b>-12,05</b>	<b>4,607</b>	
log( <i>VDMA</i> )	-0,042	0,365	-0,183	<b>0,707</b>	<b>0,295</b>	<b>3,049</b>	<b>0,691</b>	<b>0,313</b>	<b>2,982</b>
<i>QI</i>	<b>0,064</b>	<b>0,016</b>	<b>1,720</b>	<b>0,070</b>	<b>0,018</b>	<b>1,862</b>	0,068	0,059	1,807
Descrição da variável	PS_4km_2011_2014								
	Acidentes sem vítimas			Acidentes com vítimas			Acidentes com mortes		
	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.
Constante	<b>-67,74</b>	<b>5,723</b>		<b>-17,24</b>	<b>4,44</b>		<b>-11,65</b>	<b>5,824</b>	
log( <i>VDMA</i> )	<b>-0,863</b>	<b>0,174</b>	<b>-3,732</b>	<b>0,848</b>	<b>0,156</b>	<b>3,669</b>	0,162	0,286	0,702
<i>QI</i>	<b>0,071</b>	<b>0,032</b>	<b>1,979</b>	<b>0,061</b>	<b>0,020</b>	<b>1,698</b>	<b>0,118</b>	<b>0,045</b>	<b>3,282</b>
<i>P_ilum</i>	<b>56,910</b>	<b>12,080</b>	<b>1,564</b>	7,472	5,458	0,205	3,107	6,239	0,085
<i>Div_pista_B</i>	-6,092	3,982	-	<b>-1,211</b>	<b>0,826</b>	-	<b>-1,392</b>	<b>0,862</b>	-
Descrição da variável	PS_4km_2015_2018								
	Acidentes sem vítimas			Acidentes com vítimas			Acidentes com mortes		
	Média	DP	Elast.	Média	DP	Elast.	Média	DP	Elast.
Constante	-21,04	13,37		-12,32	7,008		-11,1	6,897	
<i>QI</i>	<b>0,091</b>	<b>0,013</b>	<b>2,398</b>	0,027	0,019	0,715	0,024	0,066	0,623

**Nota:** DP é o desvio padrão; Elast. é a elasticidade; Os valores em negrito referem-se aos coeficientes estatisticamente significativos a um nível de significância de 5%; *Div\_pista\_B* e *Uso\_solo\_U* são indicadores binários, não sendo aplicável a elasticidade.

Para os modelos apenas com variáveis significativas a correlação entre os efeitos latentes dos níveis de severidade é ainda maior. A correlação entre *NASV-NACV* varia de 0,93 a 0,99, entre *NASV-NACM* de 0,65 a 0,98 e, entre *NACV-NACM* vai de 0,66 a 0,98.

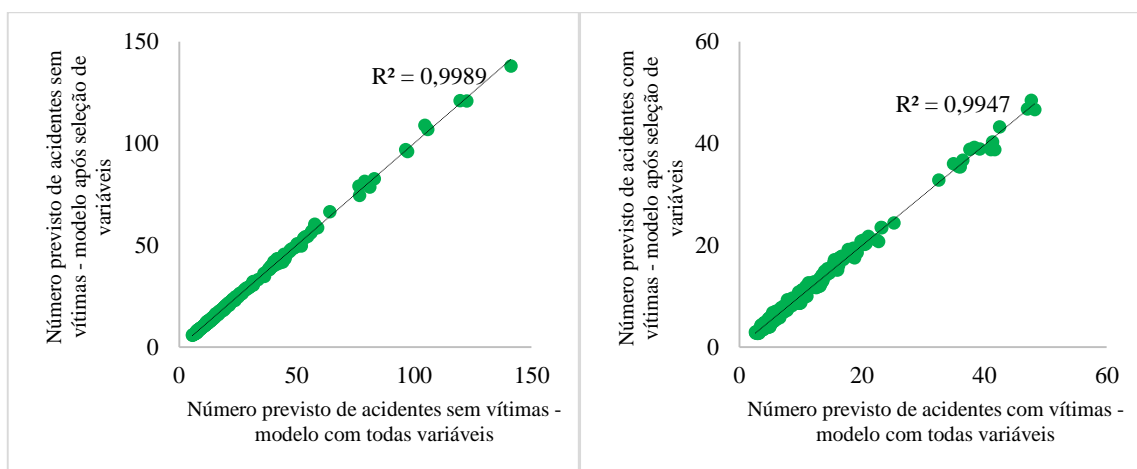
Apesar de a seleção das variáveis nos modelos MVLPN ter sido realizada empregando *backward selection* de modo adaptado, todos os modelos resultantes da seleção de variáveis tiveram desempenho comparável aos modelos originais (com uso de todas as variáveis explicativas), como pode ser verificado no Apêndice C e Tabela 6.19.

**Tabela 6.19** – Comparação entre métricas dos modelos originais e modelos resultantes da seleção de variáveis – MVPLN

Modelo	NASV		NACV		NACM	
	ER	R <sup>2</sup>	ER	R <sup>2</sup>	ER	R <sup>2</sup>
PN_3,5km_2011_2014	0,119 <b>(0,145)</b>	0,881 <b>(0,855)</b>	0,131 <b>(0,126)</b>	0,87 <b>(0,876)</b>	0,809 <b>(0,888)</b>	0,194 <b>(0,118)</b>
PN_3,5km_2015_2018	0,075 <b>(0,073)</b>	0,925 <b>(0,927)</b>	0,123 <b>(0,124)</b>	0,878 <b>(0,877)</b>	0,886 <b>(0,926)</b>	0,115 <b>(0,082)</b>
PS_4km_2011_2014	0,137 <b>(0,133)</b>	0,863 <b>(0,867)</b>	0,106 <b>(0,109)</b>	0,894 <b>(0,892)</b>	0,85 <b>(0,868)</b>	0,155 <b>(0,139)</b>
PS_4km_2015_2018	0,082 <b>(0,082)</b>	0,918 <b>(0,918)</b>	0,14 <b>(0,131)</b>	0,86 <b>(0,87)</b>	0,798 <b>(0,829)</b>	0,202 <b>(0,179)</b>

**Nota:** ER é o erro relativo; R<sup>2</sup> é o coeficiente de determinação; A primeira linha refere-se aos valores resultantes dos modelos originais; Na segunda linha, os valores em negrito e entre parênteses são relativos aos modelos resultantes da seleção de variáveis.

Quando comparados os valores previstos pelos modelos originais com os resultantes dos modelos com variáveis priorizadas, nota-se quase plena convergência para acidentes sem vítimas e com vítimas, como pode ser observado na Figura 6.33, a título de exemplo.



**Figura 6. 33-** Gráfico de dispersão entre valores previstos de acidentes (sem vítimas e com vítimas) pelo modelo original e modelo após seleção de variáveis – PS\_4km\_2011\_2014

Ao analisar a Figura 6.33, justifica-se a semelhança entre as métricas das duas abordagens e também sugere que, as variáveis significativas, por menor número que seja, são suficientes para o ajuste aceitável dos modelos e para obter boas previsões.

A importância de cada variável explanatória para a explicação da variável dependente pode ser diferente, a depender da técnica empregada, tendo em conta os distintos pressupostos e forma de funcionamento de cada uma. Os modelos estatísticos consideram a independência das variáveis explicativas enquanto que as RNA capturam e modelam a interação entre tais variáveis. No caso em estudo, o volume de tráfego (*VDMA*) se revelou ser significativo para pelo menos dois níveis de severidade em dois dos quatro modelos selecionados MVPLN. Essa variável também foi tida como importante por meio dos métodos de análise de sensibilidade conduzidos nos resultados dos modelos de RNA. De forma mais específica, para o modelo PN\_3,5km\_2011\_2014 o *VDMA* não foi significativo e o método de Sobol' indicou ser a contribuição individual dessa variável muito pequena, sendo sua influência devida a interação com outras variáveis. Já para o modelo PN\_3,5km\_2015\_2018, o *VDMA* apresentou influências direta e total altas para o modelo de RNA e também foi tido como fator significativo no modelo MVPLN. Comportamento similar foi observado para os modelos da Pista Sul em que, no primeiro período o volume de tráfego foi tido como significativo no modelo MVPLN e também como de grande influência direta e total para o modelo de RNA, enquanto que de 2015 a 2018 o *VDMA* foi significativo apenas para um nível de severidade do modelo estatístico e apresentou influência direta muito pequena no modelo de RNA.

Por outro lado, o uso do solo (*Uso\_solo\_U*) e divisão de pista (*Div\_pista\_B*) indicados pela análise de sensibilidade como os menos influentes para a variação das variáveis de saída dos modelos de redes neurais, foram observados como significativos em dois modelos MVPLN. O modelo PN\_3,5km\_2011\_2014, especificamente, tem essas duas variáveis como as únicas explicativas do modelo. Ainda que o modelo tenha sido bem ajustado, essas duas variáveis categóricas binárias, resultantes de valores predominantes nos segmentos (pequeno nível de especificidade), parecem não ser suficientes para explicar a ocorrência de acidentes.

A proporção de iluminação (*P\_ilum*), tida como significativa em um dos modelos, também se mostrou importante em alguns modelos pelo método de Sobol' e de Morris. O que também ocorreu com *QI*, que no caso estatístico foi revelada como significativa em três modelos e ainda variável única do modelo PS\_4km\_2015\_2018. Embora estudos mostrem a associação entre

condições do pavimento e ocorrência de acidentes, o que se sugere aqui, para o entendimento do fenômeno a investigação de somente essa variável não é razoável, o que também pode ser fruto de problemas ou padrões na base de dados disponível.

Vê-se, então, a patente alternativa de priorização de variáveis explicativas para o modelo MVPLN, contudo, devendo ser procedida sem que se perca a utilidade de entender o relacionamento entre as variáveis para explicação da ocorrência de acidentes. Considerando que na abordagem original, com o uso de todas as variáveis explicativas, foram obtidos resultados aceitáveis de previsão e ainda se teve uma gama mais ampla de variáveis significativas – e maior interpretabilidade decorrente disso –, certamente é possível que o desenvolvimento de uma estratégia mais apropriada à abordagem de modelos multivariados conduza a resultados superiores tanto de previsão de valores quanto de interpretabilidade de efeitos.

#### **6.4. CONSIDERAÇÕES FINAIS**

Os modelos de RNA, para além da validade replicativa, apresentaram validade preditiva. Ou seja, mostraram capacidade de generalização sobre conjuntos de dados desconhecidos, condição necessária para realização de previsões. Os modelos de MVPLN, embora apresentem desempenho aceitável quanto ao ajuste do modelo e previsões resultantes (validade replicativa), não permitem a validação preditiva, uma vez que, os efeitos latentes que são úteis na captura da correlação existente entre os níveis de severidade dos acidentes são necessários para o cômputo dos valores previstos, inviabilizando a utilização direta dos coeficientes estimados dos modelos para previsões a partir de novos dados.

Uma descoberta interessante válida para as duas abordagens foi a de que, os modelos tendem a ter melhor ajuste à medida que os segmentos tornam-se mais extensos, atingindo-se a estabilização ou ligeira queda de desempenho. Foi verificado que para a Pista Norte, em ambos períodos de tempo e, tanto para RNA quanto para MVPLN, que o segmento com extensão de 3,5 km conduziu aos melhores resultados e apresentando validade replicativa. Para a Pista Sul os resultados também foram convergentes apontando para a extensão de 4 km como a mais adequada.

De todo modo, em termos de conclusão geral é factível afirmar que os resultados obtidos indicam que, a partir de 3,5 km, a extensão do segmento deixa de ser preponderante para a previsão dos acidentes. Ou seja, utilizar extensão de 3,5 km, 4 km, 4,5 km ou 5 km resultará em desempenhos bastante similares. Esse resultado, inclusive, converge para o constatado por Green (2018).

Em termos de validade estrutural, verificou-se a existência de métodos de análise de sensibilidade adequados para utilização em modelos de redes neurais. Apesar disso, são formas indiretas de investigação do relacionamento das variáveis de entrada em relação as variáveis dependentes. O método de Sobol' e de Morris revelaram comportamento altamente não linear entre as variáveis explicativas e as saídas do modelo e ainda, existência de interação entre os *inputs* (efeitos de segunda ordem) para provocar variação nas variáveis dependentes. Embora pouco revelador, o perfil de sensibilidade reforçou o comportamento não linear das variáveis e evidenciou que a contribuição de todas as variáveis para as respostas do modelo (interação entre *inputs*). Por fim, o emprego de *Random Forest* para obtenção dos fatores de importância se mostrou adequado, apontando com razoabilidade os fatores de maior importância, a exemplo da evidente predominância do volume de tráfego. À vista disso, considera-se que os modelos de RNA têm validade preditiva e, parcialmente, validade estrutural.

Doutro lado, mesmo não sendo uma validação estrutural propriamente, a análise dos coeficientes estimados dos modelos MVPLN permitiu avaliar o relacionamento entre variáveis de entrada e saída, objetivo dessa validação. De todas as variáveis explicativas empregadas, entre 5 e 13 foram significativas, a depender do modelo. Foi então possível avaliar o efeito dessas nas variáveis dependentes. A maior parte das variáveis implicaram em efeitos consistentes, mesmo que em alguns casos contrários a constatações da literatura. Ao passo que, três variáveis não apresentaram consistência de efeitos, ora associando-se positivamente com a ocorrência de acidentes, ora negativamente.

Explorando e buscando tirar maior proveito dos modelos MVPLN, empregou-se um método de seleção de variáveis, obtendo-se, entretanto, conjuntos muito reduzidos de variáveis explicativas. Ainda assim, tais modelos conduziram a resultados semelhantes aos auferidos nos modelos originais com uso de todas as variáveis de entrada. Isso demonstra o claro potencial de redução do número de variáveis independentes antes do emprego dos modelos MVPLN, desde que com um método de maior adequação, cuidando para que o maior número de variáveis

significativas seja incorporado ao modelo. Isso converge com a colocação de Cafiso *et al.* (2008) e Cafiso *et al.* (2010), os quais afirmam que a escolha dos modelos não deve se pautar apenas na qualidade de ajuste, podendo se optar por um modelo com ajuste inferior, mas que tenha maior valor na prática de engenharia, a exemplo de um com pelo menos um fator relacionado à exposição, geometria, operação e contexto do acidente.

Entende-se, portanto, que ambas as abordagens (RNA e MVPLN) oferecem vantagens de aplicação ao problema em estudo, mas também possuem limitações. De um lado, os modelos de redes neurais mostraram adequação ao ajuste de dados de treinamento e de teste (validade replicativa e preditiva), mas têm a interpretabilidade dificultada. De outro, os modelos MVPLN são replicativamente válidos, mas não permitem a previsão de novos casos a partir dos coeficientes estimados do modelo (impedimento à validação preditiva). Contudo, adicionalmente, por meio da análise dos coeficientes estimados e valores de elasticidade permitem a investigação dos efeitos das variáveis significativas. Destarte, a depender do propósito da modelagem uma ou outra abordagem pode ser mais adequada, sendo plausível também a associação de ambas.

## **7. RANQUEAMENTO E IDENTIFICAÇÃO DE SEGMENTOS CRÍTICOS**

O alcance dos objetivos do projeto, por si só, permite a utilização dos resultados para nortear decisões e procedimentos de Gerenciamento da Segurança Viária (GSV), de forma a otimizar recursos e permitir ações mais efetiva para melhoria das condições de segurança na circulação de veículos. Ainda assim, como forma de destacar a aplicação prática potencial dos modelos desenvolvidos, procedeu-se ao ranqueamento dos segmentos e a identificação dos locais críticos.

### **7.1. PROCEDIMENTO PARA RANQUEAMENTO E IDENTIFICAÇÃO DE SEGMENTOS CRÍTICOS**

Após a obtenção do número esperado de acidentes segundo cada nível de severidade, os segmentos rodoviários analisados podem ser ranqueados a partir de apropriado parâmetro de decisão para investigação e tratamentos adicionais de engenharia (WANG *et al.*, 2011).

A classificação dos segmentos é o primeiro passo no processo de melhoria das condições de segurança do local. O segundo passo do processo é a condução de um Estudo Detalhado de Engenharia (EDE) para os locais com classificação mais alta. O objetivo do EDE é definir projetos eficazes para incrementar a segurança viária (HAUER *et al.*, 2004). Assim, os escassos recursos destinados ao GSV podem ser mais efetivos.

Conforme Cafiso *et al.* (2007), o Índice de Segurança (IS) a ser empregado para classificação dos segmentos deve combinar três componentes de risco: a exposição dos usuários aos perigos da rodovia (fator de exposição), a probabilidade de um veículo estar envolvido em um acidente (frequência de acidente) e as consequências resultantes (severidade do acidente).

Hauer *et al.* (2004) investigou algumas alternativas de ranqueamento da insegurança de segmentos rodoviários, apontando os locais com maior número de acidentes e maior índice de severidade (número de acidentes ponderado pela severidade) como estratégias mais adequadas para a seleção de locais alvo de contramedidas de engenharia.

Adicionalmente, outros autores (MIAOU & SONG, 2005; AGUERO-VALVERDE & JOVANIS, 2009; HUANG *et al.*, 2009; WANG *et al.*, 2011) afirmam que o indicador de

classificação de taxa de acidentes considerando o custo de acidentes por nível de severidade também é fortemente recomendado.

Nesse enfoque, foram adotados os critérios de ranqueamento de segmentos elencados na sequência. Destaca-se, outrossim, que para esses cálculos foram considerados os valores acumulados de acidentes em quatro anos, isto é, as análises foram conduzidas por período de tempo: 2011-2014 e 2015-2018.

### 7.1.1. Número Total de Acidentes

A partir dos dados observados e dos dados previstos em cada abordagem, foi possível calcular o Número total de acidentes (*NTA*) no segmento da seguinte forma:

$$NTA = \sum_{t=1}^4 NASV_{i,t} + NACV_{i,t} + NACM_{i,t} \quad (7.1)$$

Em que:  $NASV_{i,t}$  é o Número de acidentes sem vítimas no segmento  $i$  no ano  $t$ ;  $NACV_{i,t}$  é o Número de acidentes com vítimas no segmento  $i$  no ano  $t$ ; e  $NACM_{i,t}$  é o Número de acidentes com mortes no segmento  $i$  no ano  $t$ .

Obtido o valor *NTA* de cada segmento, eles foram ordenados de forma decrescente, de tal forma que os segmentos indicados no topo do ranqueamento correspondem aos com maior número acumulado de acidentes totais.

### 7.1.2. Taxa de Severidade dos Acidentes

Em concordância com CEFTRU (2002), empregou-se a Técnica da Taxa de Severidade dos Acidentes – também referida como *Critical Crash Rate* na literatura internacional, segundo Cafiso *et al.* (2012) – que relaciona a Unidade Padrão de Severidade (UPS) com fatores de exposição (volume de tráfego, extensão do segmento e período de análise), conforme Equações 7.2 a 7.4. Os pesos considerados, de acordo com DENATRAN (1987) são: peso 1 para acidentes com danos materiais (acidentes sem vítimas), peso 4 para acidentes com vítimas feridas e peso 13 para acidentes com mortes.



$$UPS_{i,t} = 1 \times NASV + 4 \times NACV + 13 \times NACM \quad (7.2)$$

$$UPS_i = \sum_{t=1}^4 UPS_{i,t} \quad (7.3)$$

$$TS_i = \frac{UPS \times 10^6}{P \times VDM \times L} \quad (7.4)$$

Em que:  $UPS_{i,t}$  é a Unidade Padrão de Severidade do segmento  $i$  no ano  $t$ ;  $UPS_i$  é a Unidade Padrão de Severidade do segmento  $i$  no período de 4 anos considerado;  $TS_i$  é a Taxa de Severidade dos Acidentes do segmento  $i$ , expressa em *acidentes por milhões de veículos x km*;  $P$  é o período de tempo do estudo, em *dias*;  $L$  é a extensão do segmento, em *km*;  $VDM$  é o

volume de tráfego médio diário ( $VDM_i = \frac{\sum_{t=1}^4 VDM_{i,t}}{4}$ ).

- Método numérico

No método numérico, mais simplificado, admite-se que todo segmento cujo  $TS_i$  calculado seja superior  $\overline{TS}$  (média de todos os valores  $TS_i$  da amostra) é um segmento crítico.

- Método do controle de qualidade da taxa (CQT)

Os segmentos foram, então, ordenados decrescentemente em função dos valores de Taxa de Severidade. Além disso, valendo-se do método proposto em DNER (1986b) e também descrito em AMC (2004), foi possível identificar dentre os segmentos quais eram críticos.

Para tanto, o valor da Taxa de Severidade de cada segmento foi comparado ao valor da Taxa de Severidade Crítica, expressa pela Equação 7.5:

$$TS_{crit_i} = \lambda_c + k \sqrt{\frac{\lambda_c}{Exp} - \frac{0,5}{Exp}} \quad (7.5)$$

Em que:  $TS_{crit_i}$  – índice crítico de referência do local  $i$ ;

$\lambda_c$  – taxa de severidade ponderada média do trecho em estudo ( $\lambda_c = \frac{\sum_i UPS_i \times 10^6}{P \times \sum_i VDM_i \times E}$ );

$k$  – coeficiente relacionado com o nível de significância requerido no teste de hipótese elaborado ( $k = 1,645$  para  $\alpha = 5\%$ );

$Exp$  – Exposição ( $Exp = VDMA_i \times P \times E_i \times 10^{-6}$ );

$UPS_i$  – Unidade Padrão de Severidade do segmento  $i$ ;

$P$  – período de tempo analisado, em *dias*;

$VDM$  – volume diário médio que passa pelo segmento; e

$E_i$  – extensão do segmento  $i$ , em *km*.

Nesse método do DNER (1986b), os resultados obtidos são fundamentados na probabilidade de ocorrência de um acidente em um determinado segmento, tendo como base comparativa uma amostra estudada. Conseqüentemente, se a probabilidade de ocorrência de acidentes de um segmento for maior do que a probabilidade de ocorrência na amostra, o segmento é considerado como crítico. Essa constatação é obtida por meio de um teste de hipótese do método.

O nível de significância é a probabilidade tolerável de incorrer no erro de rejeitar  $H_0$ , quando  $H_0$  é verdadeira. Assim, quando a Taxa de Severidade do segmento é maior que a sua Taxa de Severidade Crítica ( $TS_i > TS_{crit_i}$ ), rejeita-se  $H_0$  e o segmento é considerado crítico. Caso contrário, se  $TS_i < TS_{crit_i}$ ,  $H_0$  não é rejeitado e a criticidade não é atribuída ao segmento. Esse método permitiu, portanto, identificar dentre os segmentos avaliados, quais figuraram como críticos. Cumpre observar que, como a extensão do segmento é característica dos modelos selecionados, não se atendeu à recomendação de DNIT e UFSC (2009) de divisão da rodovia em trechos de 1 km.

### 7.1.3. Custo Médio de Acidentes

O indicador de classificação mais comum é a taxa de acidentes, mas o custo de acidente por nível de severidade associado a esse indicador também é fortemente recomendado, especialmente quando a gravidade do acidente e os custos associados são de maior interesse dos gestores (MIAOU & SONG, 2005). Diante disso, a classificação dos segmentos por custo médio total dos acidentes foi procedida nesse trabalho.

Para essa abordagem foram utilizados os valores de custo médio dos acidentes por nível de severidade referidos em IPEA (2015), procedendo-se à correção de valores segundo o Índice Nacional de Preços ao Consumidor Amplo (IPCA) para cada um dos anos em estudo.

O custo médio total de cada segmento foi calculado pelas Equações 7.6 e 776 e, obtido o custo médio total dos acidentes de cada segmento no período analisado, os segmentos foram ordenados de forma decrescente.

$$CT_{i,j} = NASV_i \times CM_{ASV,j} + NACV_i \times CM_{ACV,j} + NACM_i \times CM_{ACM,j} \quad (7.6)$$

$$CT_i = \sum_j CT_{i,j} \quad (7.7)$$

Em que:  $CT_{i,j}$  – custo total médio de acidentes do segmento  $i$  no ano  $j$ ;

$NASV_i$  – número de acidentes sem vítimas no segmento  $i$  no ano  $j$ ;

$CM_{ASV,j}$  – custo médio de acidente sem vítimas no ano  $j$ ;

$NACV_i$  – número de acidentes com vítimas no segmento  $i$  no ano  $j$ ;

$CM_{ACV,j}$  – custo médio de acidente com vítimas no ano  $j$ ;

$NACM_i$  – número de acidentes com mortes no segmento  $i$  no ano  $j$ ;

$CM_{ACM,j}$  – custo médio de acidente com mortes no ano  $j$ ; e

$CT_i$  – custo total médio de Acidentes no segmento  $i$  no período de tempo 2011-2014 ou 2015-2018.

Além da classificação pelo custo de acidente, DNIT e UFSC (2010) destacam que é necessário estabelecer prioridades para análise de fatores que melhor definem a relevância do trecho a ser estudado. Posto isto, empregou-se de forma simplificada o método apresentado em apresentado em DNIT e UFSC (2010) para priorização de segmentos críticos.

Para tanto, inicialmente foram tomados os  $CT_i$  como Índice Relativo de Gravidade do segmento  $i$  ( $IRG_i$ ), ou seja  $CT_i = IRG_i$ . A partir dele e dos fatores de exposição (volume de tráfego, período de tempo e extensão), procedeu-se ao cálculo do Fator de Gravidade de cada segmento ( $FG_i$ ) e Fator de Gravidade limite ( $FG_{lim}$ ) do conjunto de segmentos críticos analisados. As equações utilizadas nessa etapa estão apresentadas a seguir:

$$FG_i = \frac{IRG_i}{P \times VDM_i \times E_i} \quad (7.8)$$

$$\mu_c = \frac{\sum IRG_i}{P \times \sum VDM_i \times E_i} \quad (7.9)$$

$$\sigma_c = \frac{\sum (FG_i - \mu_c)^2}{n(n-1)} \quad (7.10)$$

$$FG_{lim} = \mu_c + \sqrt{10} \sigma_c \quad (7.11)$$

Em que:  $FG_i$  – Fator de Gravidade do segmento  $i$ ;

$IRG_i$  ( $IRG_i = NASV_i \times CM_{ASV} + NACV_i \times CM_{ACV} + NACM_i \times CM_{ACM}$ ) – Índice Relativo de Gravidade do segmento  $i$ ;

$P$  – período de Tempo, em *dias*;

$VDM_i$  – volume médio de tráfego no segmento  $i$ ;

$E_i$  – extensão do segmento  $i$ , em km;

$\mu_c$  – média dos fatores de gravidade dos segmentos;

$\sigma_c$  – desvio padrão dos fatores de gravidade dos segmentos;

$n$  – número de segmentos críticos analisados; e

$FG_{lim}$  – Fator de Gravidade Limite para o conjunto de segmentos analisado.

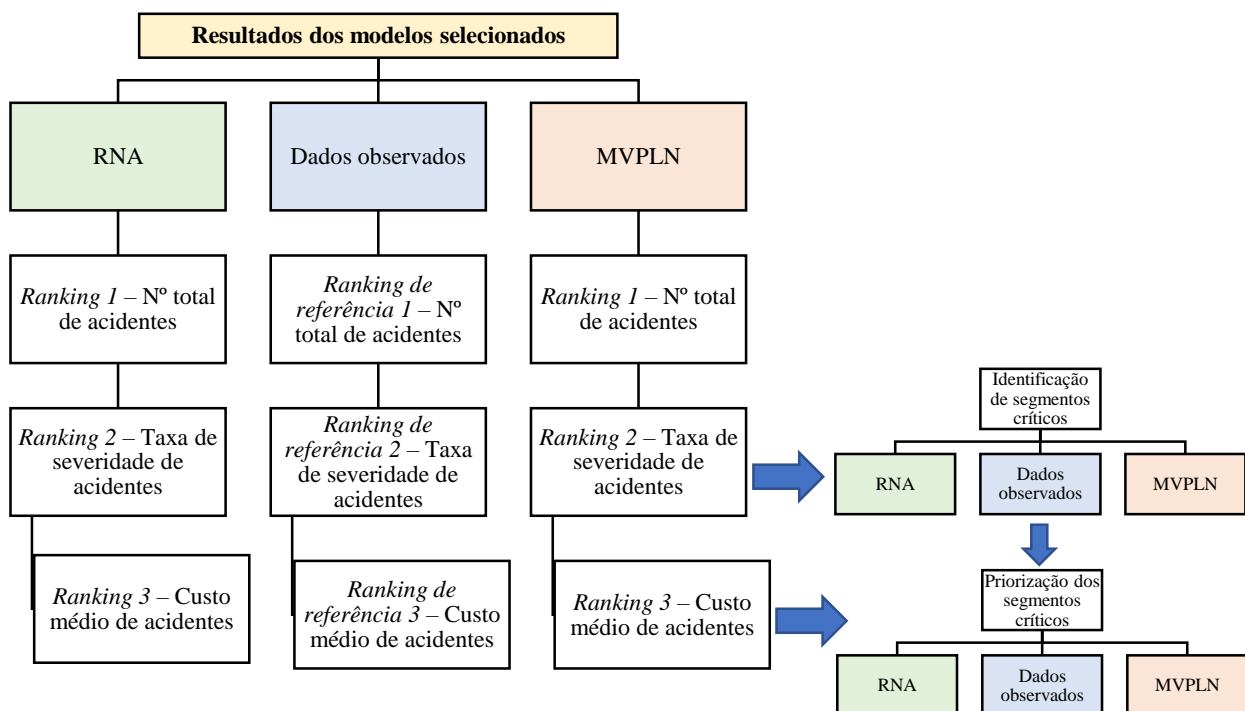
Os fatores de gravidade medem o custo dos acidentes em função dos veículos que trafegam pelo segmento. Considerando o intervalo, no qual se espera que um valor qualquer de  $FG_i$  tenha 90% ou mais de probabilidade de não corresponder a um segmento crítico prioritário, tem-se que se  $FG_i > FG_{lim}$ , o segmento crítico é tido como prioritário. Foi possível, então, identificar quais segmentos críticos merecem prioridade de intervenção.

#### 7.1.4. Análises

Os ranqueamentos produzidos permitiram analisar a concordância dos resultados entre valores observados e previstos por cada abordagem (MVPLN e RNA), bem como identificação e

priorização dos segmentos críticos. Na Figura 7.1 está apresentado o esquema geral conduzido no processo de aplicação dos resultados dos modelos selecionados.

Os dados de acidentes de trânsito são suscetíveis ao fenômeno estatístico de regressão à média, quando analisados longos períodos de observação, que ocorre quando períodos com índices absolutos excessivamente elevados ou reduzidos de acidentes são seguidos por períodos com índices absolutos de acidentes mais próximos (HAUER, 1997). Dado o período de tempo analisado neste estudo e as constatações observadas, esse efeito pareceu não comprometer os resultados deste trabalho. Ainda assim, recomenda-se que, em análises de períodos mais longos em que este efeito seja mais nítido, seja empregado o método empírico de Bayes (EB) para compensação desse fenômeno (FRAMARIM, 2003).



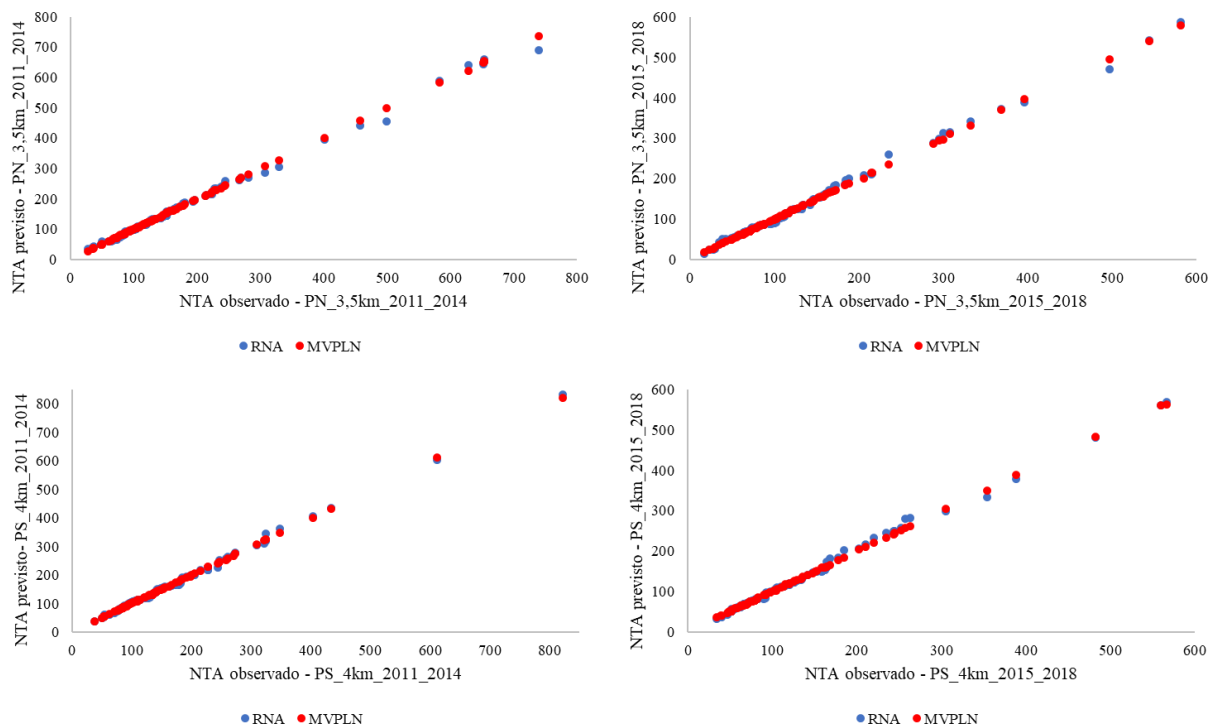
**Figura 7.1**– Procedimento geral para ranqueamento e identificação de segmentos críticos

## 7.2. RESULTADOS DO RANQUEAMENTO E IDENTIFICAÇÃO DE SEGMENTOS CRÍTICOS

Nesta seção estão apresentados os resultados de ranqueamento dos segmentos, bem como da identificação e priorização dos segmentos críticos.

### 7.2.1. Número Total de Acidentes

Por meio da soma dos valores de  $NASV_{i,j}$ ,  $NACV_{i,j}$  e  $NACM_{i,j}$ , obteve-se o Número total de acidentes ( $NTA_i$ ) tanto observado, quanto previsto pelos modelos RNA e MVPLN. Na Figura 7.2 estão apresentados os gráficos de dispersão entre os valores previstos por cada modelo e os valores observados. Nota-se para todos os modelos, em ambas as abordagens, a convergência entre os valores observados e previstos, com  $R^2$  superior a 0,95 em todos os casos.



**Figura 7.2** – Número total de acidentes observados versus número total de acidentes previstos pelos modelos RNA e MVPLN

A partir do ordenamento decrescente dos valores acumulados de acidentes por segmento, obteve-se o ranqueamento apresentado na Tabela 7.1, onde são destacados os 25 segmentos melhor classificados. A coluna “Ref.” é relativa ao ranqueamento de referência, obtido a partir dos dados observados. Quanto mais convergente for a classificação dos modelos RNA e MVPLN em relação a essa coluna, mais precisas e úteis são as previsões para a identificação de segmentos com acumulação de acidentes.

É nítida a semelhança entre o conjunto de segmentos de referência e os obtidos a partir dos modelos RNA e MVPLN, em todos os casos. A abordagem com MVPLN conduziu a resultados especialmente interessantes. Para o modelo PN\_3,5km\_2015\_2018, à exceção da inversão das

posições 12 e 13, todas as posições de referência coincidem com as posições oriundas da abordagem estatística. O mesmo ocorre no modelo PS\_4km\_2011\_2014, onde apenas ocorre a inversão entre a 7ª e a 8ª posição.

Adicionalmente, verifica-se que apenas o segmento PN23 para o primeiro modelo, segmentos PS5 e PS13 para o terceiro modelo e, segmentos PS33 e PS67 para o quarto modelo, não figuram entre os conjuntos selecionados. Ou seja, em comparação com o ranqueamento de referência, apenas tais segmentos não constam no rol dos 25 mais bem classificados. Para o segundo modelo (PN\_3,5km\_2015\_2018) todos os segmentos posicionados no *ranking* de referência também constam nos *rankings* das abordagens RNA e MVPLN. Tais resultados demonstram a adequabilidade de se proceder ao ranqueamento de segmentos, a partir dos valores previstos de acidentes totais resultantes dos modelos selecionados.

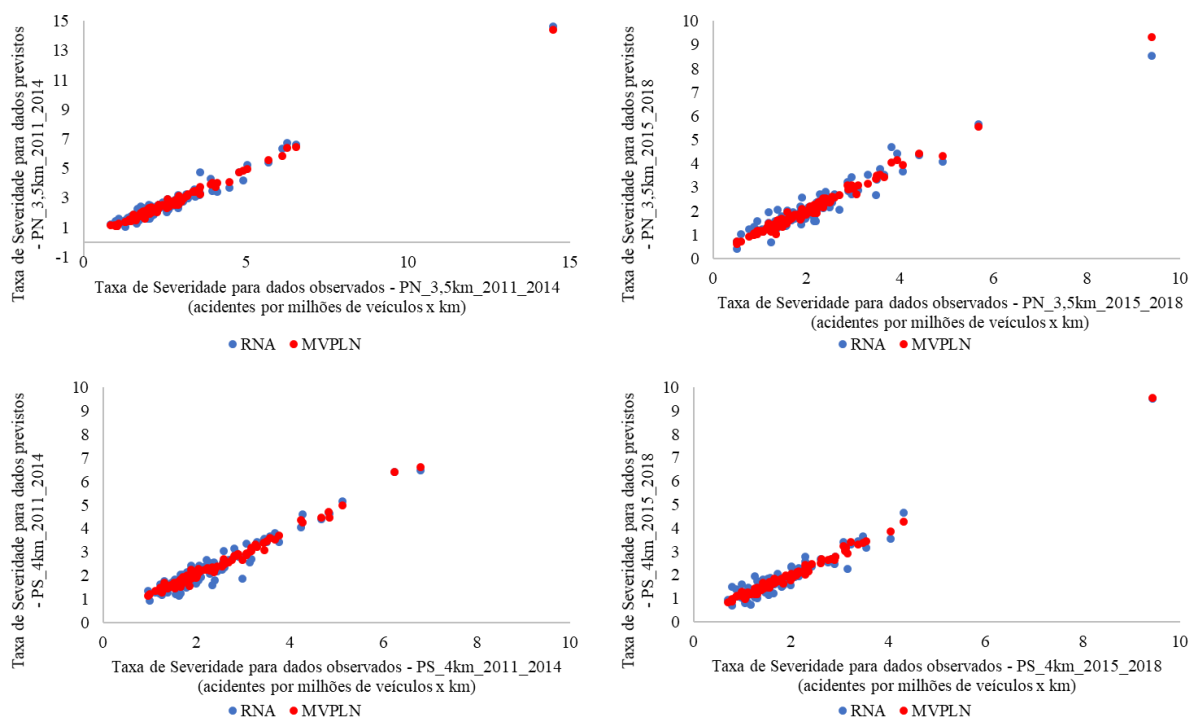
**Tabela 7.1** – Ranqueamento de segmentos em termos de número total de acidentes acumulados

Posição	PN_3,5km_2011_2014			PN_3,5km_2015_2018			PS_4km_2011_2014			PS_4km_2015_2018		
	Ref.	RNA	MVPLN	Ref.	RNA	MVPLN	Ref.	RNA	MVPLN	Ref.	RNA	MVPLN
	Segmento			Segmento			Segmento			Segmento		
1	PN100	PN100	PN100	PN86	PN86	PN86	PS2	PS2	PS2	PS2	PS2	PS2
2	PN87	PN99	PN87	PN98	PN98	PN98	PS1	PS1	PS1	PS14	PS14	PS14
3	PN99	PN86	PN86	PN16	PN16	PN16	PS75	PS75	PS75	PS75	PS75	PS75
4	PN86	PN98	PN99	PN87	PN15	PN87	PS3	PS3	PS3	PS3	PS3	PS3
5	PN98	PN87	PN98	PN15	PN87	PN15	PS74	PS74	PS74	PS1	PS1	PS1
6	PN16	PN16	PN16	PN99	PN99	PN99	PS14	PS77	PS14	PS73	PS73	PS73
7	PN15	PN97	PN15	PN13	PN13	PN13	PS4	PS14	PS76	PS74	PS74	PS74
8	PN97	PN15	PN97	PN100	PN97	PN100	PS76	PS4	PS4	PS76	PS76	PS76
9	PN13	PN13	PN13	PN97	PN100	PN97	PS77	PS76	PS77	PS4	PS77	PS4
10	PN24	PN24	PN24	PN17	PN17	PN17	PS73	PS73	PS73	PS25	PS25	PS77
11	PN17	PN88	PN17	PN24	PN24	PN24	PS78	PS78	PS78	PS66	PS65	PS25
12	PN26	PN7	PN26	PN26	PN85	PN25	PS25	PS25	PS25	PS77	PS4	PS66
13	PN88	PN17	PN88	PN25	PN25	PN26	PS33	PS33	PS33	PS65	PS66	PS65
14	PN12	PN26	PN12	PN71	PN26	PN71	PS24	PS26	PS24	PS78	PS72	PS78
15	PN7	PN12	PN7	PN88	PN88	PN88	PS32	PS32	PS32	PS72	PS78	PS72
16	PN85	PN85	PN85	PN85	PN71	PN85	PS26	PS24	PS26	PS13	PS13	PS13
17	PN74	PN25	PN74	PN82	PN18	PN82	PS66	PS6	PS66	PS6	PS6	PS6
18	PN72	PN27	PN72	PN18	PN82	PN18	PS6	PS66	PS6	PS26	PS26	PS26
19	PN25	PN72	PN25	PN12	PN96	PN12	PS31	PS31	PS31	PS24	PS24	PS24
20	PN14	PN74	PN14	PN96	PN23	PN96	PS12	PS12	PS12	PS33	PS56	PS67
21	PN27	PN18	PN27	PN23	PN12	PN23	PS13	PS27	PS13	PS67	PS12	PS12
22	PN96	PN14	PN18	PN75	PN75	PN75	PS67	PS29	PS67	PS12	PS64	PS33
23	PN18	PN96	PN96	PN90	PN74	PN90	PS5	PS67	PS5	PS56	PS32	PS56
24	PN1	PN22	PN1	PN14	PN90	PN14	PS29	PS72	PS29	PS64	PS53	PS64
25	PN23	PN1	PN23	PN74	PN14	PN74	PS65	PS65	PS65	PS32	PS79	PS32

**Nota:** Ref. é o ranqueamento de referência, obtido a partir dos dados observados.

## 7.2.2. Taxa de Severidade dos Acidentes

O segundo critério empregado para o ranqueamento dos segmentos foi a Taxa de Severidade dos Acidentes (TS). Na Figura 7.3 estão apresentados os gráficos de dispersão entre os valores de taxa de severidade calculados a partir dos dados observados e os valores de taxa de severidade calculados para os resultados das abordagens RNA e MVPLN, e para cada modelo. Em todos os casos, especialmente para os modelos MVPLN, é verificada alta convergência dos valores da Taxa de Severidade dos acidentes. São notados também alguns pontos discrepantes que, mais à frente, foram identificados como segmentos críticos prioritários.



**Figura 7.3** – Taxa de severidade dos acidentes observada versus taxa de severidade dos acidentes prevista a partir dos modelos RNA e MVPLN

A partir dos valores computados de Taxa de Severidade, foi confeccionado o ranqueamento, do qual são destacados os 25 segmentos melhor classificados em cada modelo, conforme disposto na Tabela 7.2. Apesar da alta convergência verificada na Figura 7.3, a coincidência de posições em relação ao *ranking* de referência não foi tão compatível quanto no caso do Número Total de Acidentes (NTA), especialmente na abordagem MVPLN.

O que se nota são inversões de posições, mas mantendo a coerência para a maioria dos segmentos mais bem classificados. No modelo PN\_3,5km\_2011\_2014 existem apenas dois e



um Falso Positivo (FP), respectivamente, para RNA e MVPLN. No caso das redes neurais, os segmentos PN12 e PN17 que deveriam constar no *rol* dos 25 segmentos superior da lista (como apontado pelos dados observados), não figuraram nele, ocupando a 27ª e 29ª posições. No modelo estatístico, o segmento PN17 na posição 25ª no *ranking* de referência, figurou na posição 28, estando fora do intervalo estabelecido para análise.

**Tabela 7. 2**– Ranqueamento de segmentos em termos da Taxa de Severidade dos acidentes

Posição	PN_3,5km_2011_2014			PN_3,5km_2015_2018			PS_4km_2011_2014			PS_4km_2015_2018		
	Ref.	RNA	MVPLN	Ref.	RNA	MVPLN	Ref.	RNA	MVPLN	Ref.	RNA	MVPLN
	Segmento			Segmento			Segmento			Segmento		
1	PN87	PN86	PN87	PN86	PN86	PN86	PS2	PS2	PS2	PS14	PS14	PS14
2	PN86	PN87	PN86	PN87	PN87	PN87	PS14	PS14	PS14	PS25	PS25	PS25
3	PN98	PN88	PN98	PN98	PN98	PN98	PS25	PS25	PS25	PS36	PS6	PS36
4	PN88	PN98	PN88	PN71	PN85	PN82	PS36	PS12	PS12	PS12	PS36	PS12
5	PN85	PN85	PN85	PN82	PN88	PN71	PS12	PS36	PS36	PS6	PS2	PS13
6	PN97	PN97	PN97	PN90	PN82	PN88	PS24	PS26	PS24	PS2	PS26	PS6
7	PN99	PN99	PN99	PN88	PN71	PN85	PS26	PS24	PS13	PS13	PS13	PS2
8	PN74	PN7	PN74	PN85	PN97	PN90	PS13	PS13	PS26	PS33	PS12	PS26
9	PN100	PN100	PN100	PN49	PN90	PN97	PS6	PS33	PS6	PS3	PS3	PS3
10	PN96	PN72	PN96	PN97	PN49	PN83	PS33	PS1	PS1	PS24	PS24	PS24
11	PN82	PN74	PN50	PN83	PN50	PN49	PS1	PS29	PS33	PS26	PS65	PS33
12	PN90	PN96	PN82	PN61	PN74	PN61	PS75	PS3	PS75	PS66	PS66	PS66
13	PN50	PN90	PN72	PN50	PN83	PN50	PS29	PS75	PS3	PS63	PS27	PS27
14	PN72	PN16	PN7	PN16	PN75	PN74	PS3	PS6	PS32	PS27	PS32	PS75
15	PN7	PN50	PN90	PN62	PN17	PN75	PS74	PS74	PS74	PS35	PS75	PS35
16	PN27	PN82	PN26	PN17	PN16	PN16	PS32	PS27	PS5	PS75	PS49	PS63
17	PN26	PN95	PN24	PN26	PN62	PN17	PS49	PS32	PS29	PS32	PS35	PS32
18	PN24	PN27	PN16	PN74	PN72	PN26	PS5	PS49	PS49	PS73	PS63	PS73
19	PN91	PN13	PN91	PN72	PN24	PN72	PS66	PS35	PS66	PS4	PS23	PS65
20	PN16	PN24	PN95	PN75	PN69	PN62	PS47	PS45	PS27	PS5	PS73	PS4
21	PN95	PN26	PN27	PN63	PN99	PN63	PS27	PS63	PS4	PS65	PS74	PS49
22	PN17	PN75	PN17	PN99	PN26	PN73	PS7	PS47	PS31	PS49	PS9	PS9
23	PN75	PN61	PN13	PN73	PN95	PN99	PS31	PS4	PS47	PS10	PS10	PS5
24	PN13	PN91	PN83	PN100	PN61	PN91	PS4	PS31	PS35	PS9	PS33	PS56
25	PN12	PN46	PN75	PN29	PN46	PN24	PS63	PS73	PS63	PS29	PS4	PS29

**Nota:** Ref. é o ranqueamento de referência, obtido a partir dos dados observados.

Analisando os demais modelos, verifica-se a ausência, em relação ao conjunto de referência, de quatro e dois segmentos no conjunto de 25 segmentos superiores listados (*top 25*) para, respectivamente, abordagem RNA e MVPLN de PN\_3,5km\_2015\_2018; dois e seis segmentos em PS\_4km\_2011\_2014; e, dois e um segmento em PS\_4km\_2015\_2018.

Por levarem em conta o volume de tráfego, em comparação com o número total de acidentes, existe maior proximidade entre os valores dos segmentos, tornando o ranqueamento mais

sensível e propício a inversões de posição. De todo modo, os resultados apresentados são aceitáveis e próximos ao auferido por Cafiso *et al.* (2012), que também utilizaram número total de acidentes e taxa de severidade para o ranqueamento.

Além do ranqueamento, empregou-se o método numérico (CEFTRU, 2002) e probabilístico (DNER, 1986b) para identificação dos segmentos críticos, tendo os resultados da aplicação sintetizados na Tabela 7.3.

**Tabela 7. 3**– Número de segmentos críticos identificados

Número de segmentos críticos	PN_3,5km_2011_2014			PN_3,5km_2015_2018		
	Ref.	RNA	MVPLN	Ref.	RNA	MVPLN
Numérico	34	31 (5)	32 (2)	34	32 (5)	34 (4)
Probabilístico	33	31 (4)	32 (1)	36	33 (4)	34 (3)
Número de segmentos críticos	PS_4km_2011_2014			PS_4km_2015_2018		
	Ref.	RNA	MVPLN	Ref.	RNA	MVPLN
Numérico	32	32 (3)	31 (2)	33	36 (3)	31 (2)
Probabilístico	32	32 (3)	29 (3)	32	36 (3)	29 (3)

**Nota:** Ref. é relativo aos dados observados. O valor entre parênteses representa o número de segmentos não coincidentes com os segmentos críticos de referência.

Todos os segmentos referidos na Tabela 7.2 foram tidos como críticos e, além desses, de quatro a nove segmentos também se enquadraram nessa condição, a depender do modelo e abordagem, como se nota na Tabela 7.3. Os segmentos apontados como críticos tanto pelo método numérico quanto pelo método probabilístico tiveram alta concordância, divergindo em um ou dois segmentos apenas.

Assim como já observado no *ranking* de 25 segmentos superiores, quase todos os segmentos críticos de referência foram também assim identificados através dos modelos RNA e MVPLN, notando-se, entretanto, sub-identificação desse tipo de segmento. Entre um e cinco segmentos críticos na amostra de referência não foram corretamente identificados a partir dos modelos RNA e MVPLN. Apesar disso, constatou-se que os 20 segmentos de maior criticidade foram adequadamente identificados em todos os casos. Isso demonstra que os modelos de RNA e MVPLN apresentam adequação para identificação de segmentos críticos, independente do método empregado (numérico ou probabilístico).

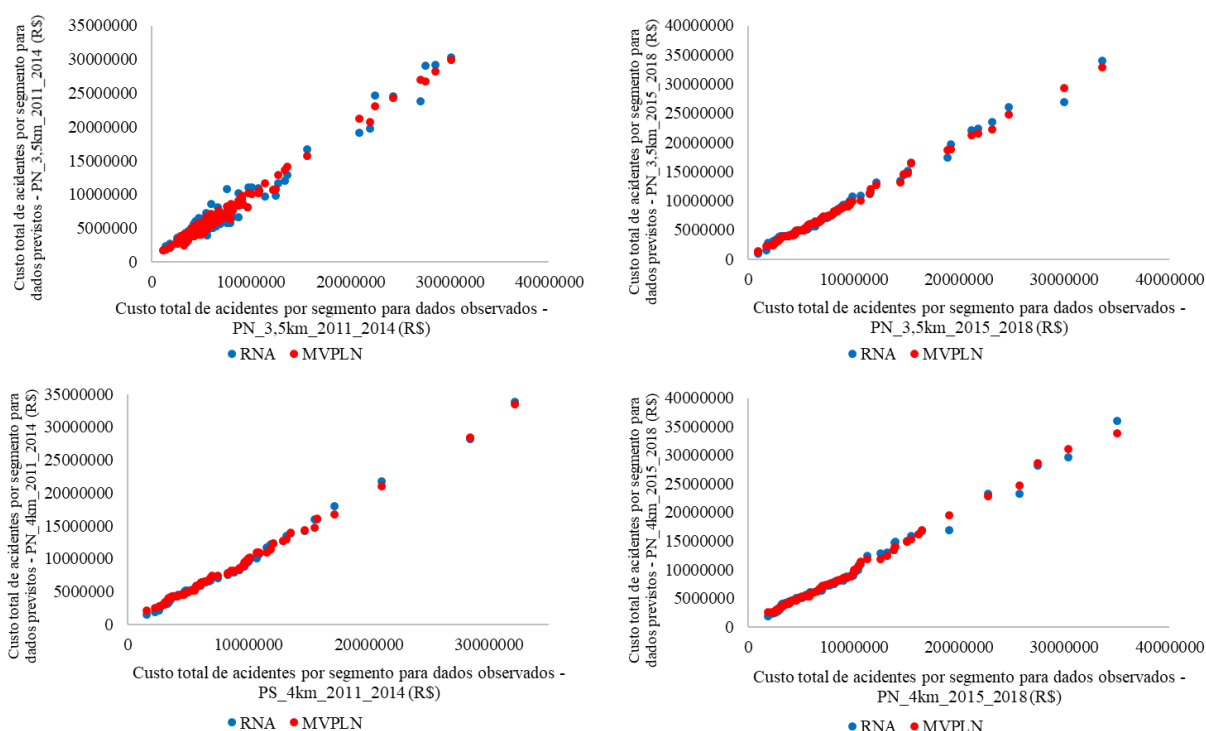
### 7.2.3. Custo Médio Total dos Acidentes

Para a hierarquização dos segmentos pelo custo médio dos acidentes, tomou-se como referência os valores médios fornecidos por IPEA (2015), corrigindo-os a partir do IPCA (Índice Nacional de Preços ao Consumidor Amplo) para todos os anos analisados, resultando na Tabela 7.4.

**Tabela 7.4** – Custo médio de acidentes por tipo de severidade

Ano	2011	2012	2013	2014
Acidentes sem vítimas	R\$ 19.759,50	R\$ 20.873,84	R\$ 22.081,41	R\$ 23.498,77
Acidentes com vítimas	R\$ 81.352,68	R\$ 85.940,58	R\$ 90.912,31	R\$ 96.747,79
Acidentes com mortes	R\$ 559.030,94	R\$ 590.557,61	R\$ 624.721,83	R\$ 664.821,46
Ano	2015	2016	2017	2018
Acidentes sem vítimas	R\$ 26.220,18	R\$ 28.017,08	R\$ 28.767,15	R\$ 29.877,72
Acidentes com vítimas	R\$ 107.952,24	R\$ 115.059,08	R\$ 118.438,48	R\$ 122.974,33
Acidentes com mortes	R\$ 741.815,03	R\$ 790.651,09	R\$ 813.873,30	R\$ 845.293,23

A partir desses valores de custos e do número de acidentes por nível de severidade, fez-se o cálculo do custo médio de acidentes por segmento. Na Figura 7.4 estão apresentados os gráficos de dispersão entre os valores de custo médio total de acidentes por segmento, calculado a partir dos dados observados e os valores obtidos a partir das previsões dos modelos RNA e MVPLN.



**Figura 7.4** – Custo médio total de acidentes para dados observados versus custo médio total de acidentes para dados previstos (modelos RNA e MVPLN)

É perceptível a congruência entre os valores resultantes dos dados observados e previstos, especialmente para a abordagem MVPLN. Para a abordagem RNA, especificamente no modelo PN\_3,5km\_2011\_2014, nota-se maior dispersão dos dados até o patamar de aproximadamente R\$ 13,5 milhões. Quando comparados à Figura 7.2, referente ao número total de acidentes, nota-se ligeira queda de convergência, como era esperado.

Baseado nos valores calculados de custos médios totais e, ordenando-os de forma decrescente, foram obtidos os ranqueamentos dos 25 segmentos mais bem classificados em cada caso, como apresentado nas Tabelas 7.5 e 7.6. Junto à posição de cada segmento, são também apresentados os valores dos custos médios totais.

Analogamente ao ocorrido nas outras duas abordagens de ranqueamento, embora não seja verificada alta coincidência entre a posição estimada por meio dos valores previstos e a posição de referência, constata-se na comparação entre os conjuntos de 25 segmentos que são predominantemente coincidentes. Para a Pista Norte no período 2011-2014, em relação ao conjunto de referência, apenas os segmentos PN1 e PN19 não figuraram no *ranking*. No período seguinte, ainda na Pista Norte, os segmentos PN1, PN27, PN29, PN63 e PN64 não foram elencados pela abordagem RNA nem os segmentos PN1, PN62 e PN64 pelo MVPLN. Em se tratando da Pista Sul, em 2011-2014 somente o segmento PS5 para abordagem RNA e segmento PS29 para MVPLN não foram coincidentes e, por fim, no período de 2015 a 2018 quatro segmentos (PS26, PS67, PS54 e PS63) não constaram no *rol* dos 25 mais bem classificados para abordagem RNA e dois (PS54, PS63) na abordagem MVPLN, quando comparados ao *ranking* de referência.

Adicionalmente, visando a priorização dos segmentos críticos fez-se a aplicação simplificada do método apresentado em DNIT e UFSC (2010) para os resultados do método probabilístico. Na Tabela 7.7 estão apresentados os resultados obtidos pela aplicação de tal método para os modelos da Pista Norte.

**Tabela 7.5 – Ranqueamento de segmentos da Pista Norte em termos de custo médio total de acidente**

Posição	PN_3,5km_2011_2014						PN_3,5km_2015_2018					
	Referência		RNA		MVPLN		Referência		RNA		MVPLN	
	Segmento	Custo total (R\$)	Segmento	Custo total (R\$)	Segmento	Custo total (R\$)	Segmento	Custo total (R\$)	Segmento	Custo total (R\$)	Segmento	Custo total (R\$)
1	PN100	30.144.914,3	PN100	30.248.604,57	PN100	29.958.042,99	PN98	33.597.060,13	PN98	34.014.029,89	PN98	32.913.561,41
2	PN98	28.541.900,46	PN98	29.182.577,22	PN98	28.189.866,42	PN16	30.008.830,81	PN16	26.893.813,32	PN16	29.308.096,14
3	PN99	27.531.078,37	PN99	29.045.031,27	PN87	26.950.650,33	PN86	24.705.655,68	PN86	26.001.066,97	PN86	24.790.884,94
4	PN87	27.068.360,01	PN16	24.665.247,77	PN99	26.736.837,45	PN100	23.126.715,29	PN15	23.512.606,19	PN15	22.277.672,55
5	PN86	24.334.962,05	PN86	24.467.672,43	PN86	24.310.984,31	PN99	21.795.193,67	PN99	22.343.894,69	PN100	21.478.055,27
6	PN16	22.498.772,31	PN87	23.812.207,85	PN16	23.061.934,35	PN15	21.219.761,57	PN100	22.038.777,11	PN99	21.190.612,5
7	PN97	21.953.323,32	PN97	19.745.066,09	PN15	21.206.998,86	PN87	19.234.594,65	PN97	19.728.189,74	PN87	18.853.144,84
8	PN15	20.867.844,09	PN15	19.131.258,14	PN97	20.720.930,77	PN97	18.883.922,85	PN87	17.396.828,61	PN97	18.661.035,9
9	PN13	15.634.863,53	PN13	16.673.119,15	PN13	15.726.618,07	PN17	15.478.232,1	PN13	16.492.588,36	PN13	16.385.830,82
10	PN24	13.668.234,48	PN24	12.905.769,9	PN24	14.076.804,46	PN71	15.110.983,59	PN17	15.109.288,71	PN17	14.694.330,7
11	PN26	13.375.363,07	PN26	11.993.978,68	PN26	13.606.354,93	PN13	14.749.557,32	PN24	14.497.060,31	PN26	14.632.372,2
12	PN17	12.734.221,11	PN17	11.628.409,76	PN17	12.815.449,7	PN26	14.449.247,12	PN25	13.456.449,05	PN25	13.136.276,52
13	PN96	12.473.054,36	PN88	1.1072.661,5	PN74	11.621.563,63	PN25	12.185.344,63	PN26	13.224.205,26	PN24	12.785.077,45
14	PN27	12.232.516,01	PN25	11.068.240,73	PN96	10.776.581,72	PN24	11.622.059,31	PN71	11.442.277,47	PN71	12.067.274,49
15	PN74	11.428.742,67	PN85	10.928.611,21	PN27	10.658.212,87	PN18	11.554.236,2	PN82	11.206.092,34	PN82	11.260.296,97
16	PN12	10.827.492,2	PN7	10.837.094,57	PN12	10.506.955,67	PN82	10.657.177,58	PN96	10.828.596,75	PN96	10.033.527,23
17	PN85	10.753.154,95	PN27	10.672.995,58	PN85	10.126.025,66	PN96	9.862.424,28	PN18	10.770.674,6	PN18	9.865.304,683
18	PN25	10.080.396,79	PN12	10.529.732,17	PN88	10.112.517,24	PN27	9.626.478,13	PN12	10.024.250,69	PN14	9.758.363,109
19	PN88	9.728.168,7	PN72	10.154.178,46	PN25	10.017.819,69	PN12	9.620.985,35	PN85	9.750.300,43	PN63	9.314.600,183
20	PN19	9.688.325,2	PN96	9.770.671,948	PN14	9.843.137,423	PN29	9.505.072,45	PN74	9.666.776,305	PN29	9.097.957,755
21	PN1	9.125.218,59	PN74	9.738.100,312	PN18	9.121.381,465	PN62	9.441.185,95	PN75	9.400.945,065	PN75	9.052.281,93
22	PN14	9.108.088,23	PN14	9.383.597,609	PN72	9.016.801,162	PN14	9.017.916,24	PN23	9 291 677,433	PN27	9.018.231,212
23	PN18	9.085.704,24	PN18	9.373.909,801	PN95	8.802.573,45	PN1	8978494,88	PN19	9 204 739,353	PN12	8.962.346,825
24	PN72	8.775.151,68	PN95	8.651.173,648	PN1	8.753.365,999	PN64	8.870.264,8	PN14	9 033 095,542	PN19	8.821.837,514
25	PN95	8.714.908,72	PN22	8.638.311,36	PN29	8.551.982,73	PN63	8.676.102,28	PN88	8 738 281,509	PN23	8.647.462,519

**Tabela 7.6 – Ranqueamento de segmentos da Pista Sul em termos de custo médio total de acidente**

Posição	PS_4km_2011_2014						PS_4km_2015_2018					
	Referência		RNA		MVPLN		Referência		RNA		MVPLN	
	Segmento	Custo total (R\$)	Segmento	Custo total (R\$)	Segmento	Custo total (R\$)	Segmento	Custo total (R\$)	Segmento	Custo total (R\$)	Segmento	Custo total (R\$)
1	PS2	47.878.446,4	PS2	44.709.076,48	PS2	45.770.298,29	PS2	35.023.979,99	PS2	36.074.219,75	PS2	33.909.700,1
2	PS1	32.158.839,7	PS1	33.795.746,1	PS1	33.413.735,7	PS75	30.389.725,92	PS75	29.664.116,79	PS75	31.028.702,18
3	PS75	28.422.764,42	PS75	28.186.424,72	PS75	28.445.408,62	PS3	27.499.908,28	PS3	28.187.736,66	PS3	28.565.251,35
4	PS3	21.106.385,82	PS3	21.776.937,04	PS3	20.999.838,12	PS1	25.781.246,59	PS14	23.278.384,15	PS1	24.733.889,04
5	PS74	17.166.909,00	PS74	17.963.242,92	PS74	16.725.291,26	PS14	22.790.130,03	PS1	23.197.555,2	PS14	22.898.391,57
6	PS4	15.728.574,12	PS77	15.990.357,81	PS4	16.144.788,25	PS4	19.097.196,95	PS4	16.956.780,01	PS4	19.466.554,31
7	PS77	15.498.775,8	PS4	15.919.226,00	PS76	14.728.963,24	PS73	16.517.202,47	PS76	16.806.419,41	PS73	16.909.865,42
8	PS73	14.661.222,67	PS73	14.252.065,57	PS77	14.328.992,14	PS66	16.184.674,01	PS73	16.147.765,13	PS76	16.155.989,64
9	PS76	13.552.509,35	PS76	13.862.060,13	PS73	13.949.019,34	PS76	15.496.932,63	PS74	15.879.356,4	PS77	15.294.853,35
10	PS25	13.205.130,8	PS25	13.453.530,28	PS25	12.971.077,66	PS77	15.072.223,59	PS25	15.018.624,71	PS66	14.900.038,1
11	PS66	12.939.242,01	PS14	12.707.353,04	PS14	12.699.177,21	PS33	13.979.848,9	PS77	14.831.379,24	PS74	13.938.861,26
12	PS14	12.114.596,3	PS26	12.272.832,78	PS66	12.269.004,79	PS74	13.847.118,14	PS66	14.670.350,29	PS78	13.814.144,29
13	PS24	11.877.609,75	PS33	12.154.130,82	PS24	11.496.324,14	PS78	13.797.232,13	PS65	13.396.101,49	PS25	13.407.661,76
14	PS6	11.679.820,31	PS24	11.774.467,19	PS32	11.207.070,42	PS25	13.157.671,12	PS72	12.954.431,46	PS33	12.392.789,17
15	PS33	11.531.463,56	PS78	11.724.843,26	PS6	11.006.584,42	PS6	12.557.967,62	PS78	12.820.975,17	PS6	11.783.977,6
16	PS32	10.928.807,72	PS32	10.672.548,82	PS33	11.003.098,6	PS5	11.275.905,82	PS6	12.454.612,53	PS65	11.778.658,59
17	PS78	10.785.653,18	PS66	10.565.016,56	PS78	10.947.025,73	PS65	10.682.874,23	PS32	11.021.923,79	PS72	11.382.532,55
18	PS26	10.737.641,48	PS65	10.015.636,13	PS26	10.932.060,24	PS72	10.483.330,46	PS26	10799409,96	PS67	10.642.463,00
19	PS12	10.171.669,98	PS6	9.939.454,844	PS5	10.140.342,8	PS67	10.391.469,78	PS24	9943987,603	PS26	10.547.031,07
20	PS31	10.038.783,73	PS67	9.779.178,998	PS13	10.079.700,73	PS56	10.228.329,82	PS53	9.581.157,399	PS56	10.034.982,91
21	PS5	10.024.096,39	PS29	9.550.438,779	PS67	9.942.077,084	PS32	10.064.771,07	PS5	9.501.662,756	PS32	9.876.585,295
22	PS29	9.926.453,1	PS31	9.460.238,481	PS31	9.732.909,681	PS24	10.025.688,97	PS56	9.435.812,175	PS24	9.636.691,995
23	PS67	9.801.269,98	PS12	9.417.291,699	PS12	9.712.178,174	PS63	9.921.675,77	PS87	8.996.185,867	PS5	9.345.327,068
24	PS13	9.692.778,11	PS27	8.967.244,97	PS65	9.467.719,742	PS53	9.693.395,71	PS33	8.983.159,635	PS55	8.847.064,304
25	PS65	9.663.444,68	PS13	8.868.217,765	PS72	8.926.767,763	PS54	9.324.292,23	PS79	8.788.812,387	PS36	8.690.667,773

**Tabela 7.7–** Fator de gravidade dos segmentos críticos e segmentos prioritários da Pista Norte

PN_3,5km_2011_2014					PN_3,5km_2015_2018						
Referência (FG <sub>lim</sub> =0,557)		RNA (FG <sub>lim</sub> =0,587)		MVPLN (FG <sub>lim</sub> =0,674)		Referência (FG <sub>lim</sub> =0,514)		RNA (FG <sub>lim</sub> =0,532)		MVPLN (FG <sub>lim</sub> =0,655)	
Seg.	FG	Seg.	FG	Seg.	FG	Seg.	FG	Seg.	FG	Seg.	FG
PN6	0,302	PN7	0,446	PN7	0,340	PN6	0,288	PN15	0,282	PN15	0,267
PN7	0,310	PN12	0,275	PN12	0,274	PN15	0,254	PN16	0,344	PN16	0,374
PN12	0,282	PN13	0,300	PN13	0,283	PN16	0,383	PN17	0,361	PN17	0,351
PN13	0,281	PN16	0,336	PN15	0,257	PN17	0,370	PN24	0,342	PN24	0,302
PN15	0,252	PN17	0,280	PN16	0,314	PN24	0,274	PN25	0,296	PN25	0,289
PN16	0,306	PN24	0,300	PN17	0,308	PN25	0,268	PN26	0,333	PN26	0,369
PN17	0,306	PN26	0,302	PN24	0,328	PN26	0,364	PN36	0,284	PN29	0,287
PN24	0,318	PN27	0,307	PN26	0,343	PN29	0,300	PN46	0,316	PN49	0,407
PN26	0,337	PN46	0,281	PN27	0,307	PN36	0,290	PN49	0,412	PN50	0,391
PN27	0,352	PN47	0,279	PN47	0,267	PN47	0,311	PN50	0,436	PN61	0,411
PN46	0,323	PN48	0,291	PN50	0,268	PN49	0,450	PN61	0,328	PN62	0,331
PN47	0,260	PN50	0,350	PN61	0,255	PN50	0,435	PN62	0,360	PN63	0,334
PN50	0,312	PN61	0,308	PN71	0,281	PN61	0,404	PN69	0,325	PN69	0,279
PN61	0,431	PN71	0,278	PN72	0,185	PN62	0,416	PN71	0,499	PN70	0,280
PN71	0,195	PN72	0,409	PN73	0,279	PN63	0,311	PN72	0,349	PN71	0,526
PN72	0,294	PN73	0,272	PN74	0,363	PN69	0,293	PN73	0,284	PN72	0,365
PN74	0,353	PN74	0,392	PN75	0,270	PN71	0,659	PN74	0,421	PN73	0,339
PN75	0,221	PN75	0,299	PN77	0,521	PN72	0,355	PN75	0,393	PN74	0,367
PN77	0,512	PN82	0,333	PN82	0,364	PN73	0,331	PN82	0,535	PN75	0,378
PN82	0,383	PN85	0,600	PN83	0,456	PN74	0,340	PN83	0,400	PN82	0,537
PN83	0,478	PN86	1,343	PN85	0,556	PN75	0,329	PN84	0,282	PN83	0,418
PN85	0,590	PN87	1,323	PN86	1,351	PN82	0,508	PN85	0,554	PN84	0,282
PN86	1,352	PN88	0,621	PN87	1,511	PN83	0,454	PN86	1,498	PN85	0,481
PN87	1,518	PN90	0,360	PN88	0,574	PN84	0,314	PN87	1,013	PN86	1,428
PN88	0,552	PN91	0,343	PN90	0,353	PN85	0,436	PN88	0,518	PN87	1,098
PN90	0,385	PN95	0,407	PN91	0,331	PN86	1,423	PN90	0,441	PN88	0,481
PN91	0,327	PN96	0,376	PN95	0,339	PN87	1,120	PN91	0,279	PN90	0,471
PN95	0,335	PN97	0,725	PN96	0,395	PN88	0,441	PN95	0,332	PN91	0,318
PN96	0,458	PN98	0,750	PN97	0,532	PN90	0,489	PN96	0,317	PN95	0,301
PN97	0,564	PN99	0,609	PN98	0,591	PN91	0,292	PN97	0,459	PN96	0,294
PN98	0,598	PN100	0,504	PN99	0,446	PN95	0,278	PN98	0,675	PN97	0,434
PN99	0,459			PN100	0,424	PN96	0,289	PN99	0,330	PN98	0,653
PN100	0,427					PN97	0,439	PN100	0,298	PN99	0,313
						PN98	0,667			PN100	0,291
						PN99	0,321				
						PN100	0,313				

**Nota:** Seg. é o segmento; FG é o Fator de Gravidade do segmento; FGlim é o fator de gravidade limite; As células hachuradas indicam os segmentos críticos prioritários.

Baseado nos valores observados, os segmentos PN85, PN86, PN87, PN97 e PN98 seriam de intervenção prioritária para a Pista Norte no período de 2011 a 2014 e os segmentos PN71,

PN86, PN87 e PN98 no período 2015-2018. Para o primeiro período, a partir dos resultados obtidos da abordagem RNA, todos os segmentos prioritários foram corretamente apontados, tendo-se ainda como prioritários os segmentos PN88 e PN99 que, no conjunto de referência têm valor FG bem próximo ao valor limite, justificando tal constatação.

No período 2015-2018, ainda com relação a RNA, três dos quatro segmentos críticos tidos como prioritários nos dados de referência também foram identificados por essa abordagem e, ainda, outros dois segmentos (PN82 e PN85) foram identificados como prioritários.

Quanto aos resultados oriundos da abordagem MVPLN, em ambos os períodos apenas os segmentos PN86 e PN87 foram identificados como prioritários, quando de fato o são no conjunto de referência. O desvio padrão dos fatores de gravidade do conjunto de dados da abordagem MVPLN foi verificado como ligeiramente superior à abordagem de referência e RNA em todos os casos, conduzindo a um valor limite de FG maior e classificação de menos segmentos como prioritários.

Em relação aos segmentos prioritários de referência, os segmentos PN86, PN87 e PN98 foram considerados prioritários nos dois períodos de tempo, com valores de FG similares entre um e outro período. Isso pode sinalizar a criticidade sistemática dos segmentos, tendo em conta a convergência de resultados mesmo diante da variação temporal e de possíveis ações mitigadoras empregadas.

De forma semelhante, também é apresentada a Tabela 7.8 com os resultados relativos a Pista Sul. Nessa pista, o número de segmentos prioritários foi superior, sendo sete no período 2011-2014 e seis no período seguinte, em termos do conjunto de referência. Os resultados baseados na abordagem RNA permitiram identificar todos os sete segmentos prioritários em 2011-2014 e indicou adicional o segmento PS26 como pertencente à mesma condição.

No período de 2015 a 2018, no entanto, foram identificados quatro segmentos prioritários, sendo destes três coincidentes com os de referência. O segmento PS2 apontado como prioritário não o sendo, tem valor de *FG* muito próximo ao *FG<sub>lim</sub>* no conjunto de referência, figurando, em ordem decrescente de valores a 7ª posição do *ranking*. De outro lado, o segmento PS36 que deveria ser classificado como prioritário pela abordagem de RNA, mas não o foi, tem valor de *FG* também muito próximo ao *FG<sub>lim</sub>*, mas inferior.



**Tabela 7.8 - Fator de gravidade dos segmentos críticos e segmentos prioritários da Pista Sul**

PS_4km_2011_2014						PS_4km_2015_2018					
Referência (FG <sub>lim</sub> =0,395)		RNA (FG <sub>lim</sub> =0,386)		MVPLN (FG <sub>lim</sub> =0,551)		Referência (FG <sub>lim</sub> =0,422)		RNA (FG <sub>lim</sub> =0,415)		MVPLN (FG <sub>lim</sub> =0,562)	
Seg.	FG	Seg.	FG	Seg.	FG	Seg.	FG	Seg.	FG	Seg.	FG
PS1	0,311	PS1	0,327	PS1	0,323	PS1	0,241	PS1	0,217	PS1	0,231
PS2	0,626	PS2	0,584	PS2	0,598	PS2	0,405	PS2	0,417	PS2	0,392
PS3	0,318	PS3	0,328	PS3	0,317	PS3	0,379	PS3	0,389	PS3	0,394
PS4	0,262	PS4	0,266	PS4	0,269	PS4	0,303	PS4	0,269	PS4	0,308
PS5	0,310	PS5	0,258	PS5	0,313	PS5	0,318	PS5	0,268	PS5	0,264
PS6	0,383	PS6	0,326	PS6	0,361	PS6	0,443	PS6	0,439	PS6	0,416
PS7	0,324	PS10	0,247	PS7	0,268	PS7	0,205	PS10	0,274	PS7	0,220
PS12	0,487	PS12	0,451	PS12	0,465	PS12	0,425	PS12	0,361	PS12	0,404
PS13	0,438	PS13	0,401	PS13	0,455	PS13	0,367	PS13	0,379	PS13	0,391
PS14	0,563	PS14	0,591	PS14	0,591	PS14	1,109	PS14	1,133	PS14	1,114
PS24	0,427	PS24	0,424	PS24	0,414	PS24	0,376	PS24	0,373	PS24	0,362
PS25	0,475	PS25	0,484	PS25	0,467	PS25	0,494	PS25	0,564	PS25	0,503
PS26	0,386	PS26	0,442	PS26	0,393	PS26	0,349	PS26	0,405	PS26	0,396
PS27	0,299	PS27	0,323	PS27	0,274	PS27	0,343	PS27	0,321	PS27	0,318
PS29	0,357	PS28	0,254	PS29	0,292	PS29	0,261	PS28	0,226	PS29	0,252
PS31	0,290	PS29	0,344	PS31	0,281	PS31	0,177	PS29	0,236	PS31	0,184
PS32	0,316	PS31	0,273	PS32	0,324	PS32	0,302	PS31	0,236	PS32	0,297
PS33	0,341	PS32	0,308	PS33	0,325	PS33	0,428	PS32	0,331	PS33	0,380
PS35	0,261	PS33	0,359	PS35	0,270	PS35	0,351	PS33	0,275	PS35	0,326
PS36	0,503	PS35	0,303	PS36	0,443	PS36	0,493	PS35	0,311	PS36	0,475
PS45	0,226	PS36	0,455	PS45	0,258	PS45	0,182	PS36	0,412	PS45	0,214
PS47	0,301	PS45	0,294	PS47	0,279	PS47	0,263	PS45	0,222	PS47	0,238
PS48	0,254	PS47	0,279	PS48	0,241	PS48	0,237	PS47	0,253	PS48	0,235
PS49	0,300	PS48	0,257	PS49	0,283	PS49	0,307	PS48	0,229	PS49	0,276
PS55	0,242	PS49	0,300	PS63	0,265	PS55	0,220	PS49	0,318	PS63	0,316
PS56	0,254	PS63	0,283	PS66	0,281	PS56	0,269	PS63	0,292	PS66	0,340
PS63	0,248	PS65	0,249	PS73	0,247	PS63	0,362	PS65	0,331	PS73	0,294
PS65	0,241	PS66	0,242	PS74	0,296	PS65	0,264	PS66	0,335	PS74	0,243
PS66	0,297	PS73	0,253	PS75	0,319	PS66	0,369	PS73	0,281	PS75	0,326
PS73	0,260	PS74	0,318			PS73	0,288	PS74	0,277		
PS74	0,304	PS75	0,316			PS74	0,241	PS75	0,311		
PS75	0,319	PS77	0,234			PS75	0,319	PS77	0,197		

**Nota:** Seg. é o segmento; FG é o Fator de Gravidade do segmento; FGLim é o fator de gravidade limite; As células hachuradas indicam os segmentos críticos prioritários.

Tais fatos apontam para a convergência de resultados e mostram a admissibilidade destes, mesmo que não tenha havido plena coincidência entre os segmentos críticos prioritários de referência e os previstos a partir das RNA.

No caso da abordagem MVPLN, assim como verificado para os modelos da Pista Norte, a variabilidade superior dos valores de *FG* permitiram a identificação de apenas dois segmentos como prioritários no período 2011-2014 e um no período 2015-2018. Todos esses resultados, em contrapartida, coincidem os de referência.

Comparando os resultados de referência nos dois períodos, percebe-se que os segmentos PS12, PS14, PS25 e PS36 mantêm-se na condição de segmento crítico prioritário em ambos períodos. Os valores de *FG* são similares nos dois períodos de tempo, à exceção do segmento PS14 que apresenta valor sensivelmente superior em 2015-2018. A recorrência da criticidade prioritária desses segmentos é interessante de ser avaliada em um estudo de engenharia.

Todos os trechos identificados como prioritários em ambos períodos estão inseridos no trecho da rodovia no estado do Rio de Janeiro, tanto na Pista Norte quanto na Pista Sul. À exceção do segmento PS14, que situa-se em região montanhosa de grandes aclives, os demais segmentos estão inseridos em áreas fundamentalmente urbanas (cidades de Piraí, Seropédica, Resende e Volta Redonda) e interagem com as atividades residenciais, comerciais e industriais. Uma análise aprofundada, que foge ao escopo deste trabalho, é necessária para, conforme sugere CEFTRU (2002), avaliar criteriosamente os locais, investigar os fatores contribuintes dos acidentes e propor tratamento para os locais críticos.

#### **7.2.4. Considerações Finais**

De forma geral, considerando os três critérios avaliados (número total de acidentes, taxa de severidade e custo médio total dos acidentes), os modelos PN\_3,5km\_2011\_2014 e PS\_2011\_2014 apresentaram alta proporção de coincidência entre os segmentos dos ranqueamentos, sendo as proporções de 18/25, 17/25 e 18/25 para as abordagens de referência, RNA e MVLPN, respectivamente, do modelo da Pista Norte; e, 19/25, 18/25 e 19/25 para as abordagens de referência, RNA e MVLPN, respectivamente, do modelo da Pista Sul. Nos outros dois modelos, embora também se note em geral concordância superior a 50%, as proporções são menores. Cada critério empregado classifica os segmentos de forma distinta, apesar disso é possível verificar a convergência plena de pelo menos 10 segmentos entre os *rankings* de cada abordagem (referência, RNA e MVPLN).

O ranqueamento em termos de acidentes totais, embora utilizado apenas quando inexistem dados de volume de tráfego e/ou impossibilidade de sua estimativa, foi o que obteve maior convergência em todos os casos. Isso era de se esperar já que, no Capítulo 6 constatou-se desempenho satisfatórios dos modelos selecionados e, portanto, no acumulado de acidentes até os inconsistentes valores previstos de mortes seriam melhor acomodados.

Quando o critério utilizado passou a ser o custo médio total dos acidentes que, para além do número de acidentes para cada nível de severidade associa o custo médio deste tipo de acidente, a congruência entre o ranqueamento de referência e os obtidos pelas abordagens RNA e MVPLN foi menor. Foi o critério da taxa de severidade, no entanto, que teve pior performance em termos de convergência entre *rankings*. Por considerar pesos diferentes para cada tipo de acidente (resultando na UPS) e ainda, associar isso a fatores de exposição (volume de tráfego, extensão de segmento e tempo), é uma medida mais elaborada e naturalmente mais difícil de convergir entre os modelos. Contudo, tanto para a abordagem RNA quanto MVPLN verificou-se coincidência de mais da metade dos segmentos desses ranqueamentos em relação ao de referência.

Em relação aos segmentos críticos, quase todos os segmentos críticos de referência também foram adequadamente assim classificados através dos modelos RNA e MVPLN, mesmo que com ligeira sub-identificação. Na priorização dos segmentos críticos também foi constatada a eficiência dos modelos, especialmente de RNA, cujos resultados revelaram correta identificação de quase todos segmentos prioritários para Pista Norte nos dois períodos e Pista Sul de 2011 a 2014.

Os resultados encontrados são consistentes com estudos anteriores (MIAOU & SONG, 2005; HUANG *et al.*, 2009; WANG *et al.*, 2011) e as diferenças entre os métodos de classificação são esperadas e devidas, principalmente, à alta natureza estocástica e esporádica dos acidentes e ao fato de os pesos e custos atribuídos aos acidentes fatais serem consideravelmente mais altos do que os outros dois tipos de acidentes (MIAOU & SONG, 2005).

Desta forma, frente a confirmação da adequabilidade dos modelos desenvolvidos no auxílio a tomada de decisão de gestores e técnicos para gestão da segurança viária, também se entende que o procedimento metodológico empregado é apropriado, viável e útil para desenvolvimento

de modelos de previsão de acidentes em rodovias e consequente subsídio a ações práticas de engenharia e fiscalização.

A indicação dos segmentos que carecem prioritariamente de estudo detalhado de engenharia possibilita análise e proposição de contramedidas que, quando são mais baratas que os custos de acidentes auferidos ali, revelam o benefício (viabilidade econômica) da intervenção. Neste sentido, um estudo conduzido pelo iRAP (2014) em rodovias no estado de São Paulo mostrou que a implantação de contramedidas de engenharia apresentaria uma Relação de Custo Benefício (RCB) de 4,43:1 ou 8,13:1 com respectivas reduções de acidentes graves e fatais em 41% e 36%.

Por fim, é interessante referir que mesmo a aplicação tendo sido restrita à rodovia estudada, o custo total dos acidentes no período analisado (2011-2018) foi estimado em cerca de vultosos R\$ 3 bilhões, não estando contabilizados nesse montante demais custos sociais e ambientais. Isso reforça o grave panorama experimentado e necessidade de serem compulsados esforços multissetoriais para sua reversão.

## 8. CONCLUSÕES E RECOMENDAÇÕES

Neste capítulo são apresentadas a síntese geral, as conclusões acerca do trabalho, as limitações identificadas e as recomendações para desenvolvimento de trabalhos futuros. Na Figura 8.1 está apresentado o resumo gráfico da tese.

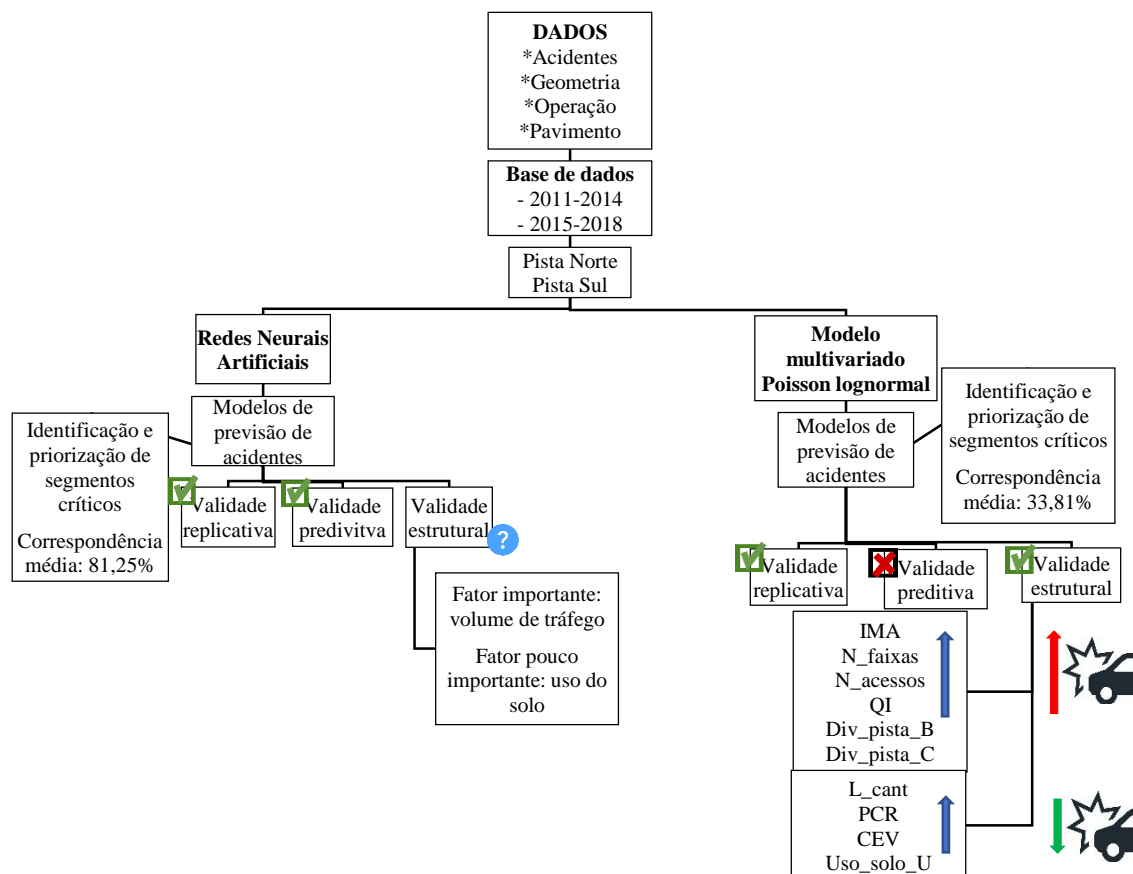


Figura 8. 1– Resumo gráfico da tese

### 8.1. SÍNTESE GERAL

Dado o cenário da acidentalidade viária ao redor do mundo, esforços multissetoriais têm sido compulsados para o enfrentamento dessa questão. Do ponto de vista de engenharia, embora se saiba que o fator humano é determinante para a ocorrência de acidente, estratégias sistêmicas precisam ser implementadas para propiciar um sistema de mobilidade seguro. A Gestão da Segurança Viária (GSV) deve, na medida que os seres humanos cometem falhas, prover uma infraestrutura viária que minimize as consequências do erro humano.

Neste contexto, o desenvolvimento de modelos de previsão de acidentes apresenta grande utilidade. A partir deles é possível associar fatores geométricos, operacionais e ambientais ao

número de acidentes que ocorre em segmento ou interseção, em um período de tempo especificado.

Modelos de resposta multivariada são ainda mais pertinentes, já que permitem a modelagem conjunta de fenômenos que efetivamente são correlacionados, tal como a frequência de acidentes segundo diferentes níveis de severidade. Isso, no entanto, demanda maior complexidade no processo de modelagem e técnicas estatísticas mais sofisticadas. Por outro lado, abordagens com Aprendizado de Máquina (AM) parecem ter potencial uso nessas situações.

Os processos e análises desenvolvidas nesta tese objetivaram desenvolver modelos de previsão de frequência de acidentes segundo diferentes níveis de severidade, a partir de dados secundários advindos da fiscalização e/ou operação rodoviária, com foco na investigação da adequabilidade do emprego de técnica de AM para esse tipo de modelagem. Para tanto, os procedimentos de pesquisa foram desenvolvidos a partir de dados de um trecho de rodovia brasileira de pista dupla, a BR-116. O trecho é constituído continuamente do km 231,6 ao km 0 (zero) no estado de São Paulo (SP) e do km 333,5 ao km 163,0 no estado do Rio de Janeiro (RJ), perfazendo um total de 402,1 km.

Os dados relativos a acidentes e características geométricas, operacionais e do pavimento foram obtidos junto à ANTT, sendo complementados por informações do sistema SIOR do DNIT e de imagens de satélite. A partir dos dados brutos fez-se a exploração da relação entre as informações neles contidas e a ocorrência de acidentes, transformando-os em variáveis úteis para o desenvolvimento dos modelos.

A Revisão Sistemática da Literatura revelou quais as técnicas mais empregadas e com maior potencial para modelagem da segurança viária. A partir disso e, mediante testes exploratórios, considerando o propósito de resposta multivariada dos modelos, as Redes Neurais Artificiais (RNA) foram utilizadas para o processo de modelagem. Mesmo não sendo o foco da pesquisa, a técnica de modelagem estatística de resposta multivariada de acidentes mais utilizada, o modelo multivariado Poisson lognormal (MVPLN), também foi empregada para fins de comparação e fortalecimento das discussões dos resultados.

A exploração dos dados permitiu verificar que a mudança do procedimento de registro de acidentes de trânsito em rodovias federais brasileiras, a partir da implantação do sistema e-DAT da PRF, implicou numa substancial queda no registro de acidentes sem vítimas (que passaram a ser registrados pelos próprios envolvidos no sinistro, através da *internet*) a partir de 2015. Considerando isso, foram realizadas duas agregações temporais dos dados para análise: período 2011-2014 e período 2015-2018.

Outro aspecto importante quanto a modelagem foi a definição da estratégia de segmentação. Embora não haja consenso, estudos recentes têm apontado para maior adequação e flexibilidade do uso de segmentos fixos, o que foi empregado nesse estudo. Apesar disso, a extensão do segmento é um parâmetro crítico dessa abordagem, motivo pelo qual a influência da extensão tornou-se um objetivo específico da tese. Para essa avaliação foram realizados dez processos de segmentação para cada pista, cada um com uma extensão diferente, variando de 500 m a 5 km (500 m, 1 km, 1,5 km, 2 km, 2,5 km, 3 km, 3,5 km, 4 km, 4,5 km e 5 km).

## **8.2. CONCLUSÕES**

O objetivo principal do trabalho “*Desenvolver modelos de previsão de frequência de acidentes por severidade em rodovia brasileira de pista dupla*” foi plenamente atendido, sendo apresentadas aqui as principais conclusões verificadas.

Os parâmetros de execução da modelagem RNA e MVPLN foram definidos de forma a otimizar o desempenho dos modelos. As tentativas empreendidas, com diferentes técnicas (*Random Forest, Boosted Trees, RNA, ACP*) revelaram que a priorização de variáveis não é vantajosa, uma vez que em todos os casos foi verificada piora no ajuste dos modelos com variáveis priorizadas. Isso ocorre, possivelmente, porque como as técnicas baseiam-se no aprendizado e tiram proveito de informações de todas as variáveis, um número maior de variáveis ligadas ao fenômeno modelado pode se refletir em mais informações úteis para as previsões do modelo.

O emprego de *transfer learning*, ou seja, estratégia de reaproveitamento do conhecimento adquirido nos modelos anteriores para inicialização do modelo atual, conduziu a melhor performance das redes neurais, mesmo com base de dados pequenas e ainda minimizaram o risco de *overfitting*. Tal fato sinaliza a oportunidade de emprego de RNA para modelagem de acidentes, mesmo com uso de um conjunto reduzido de dados.

Os resultados, de forma a conferir maior robustez e confiança às constatações, foram avaliados segundo os aspectos de validade replicativa, preditiva e estrutural. A verificação de validade replicativa garante que o modelo captura adequadamente o relacionamento subjacente nos dados utilizados para calibração (treinamento). Para tanto, diversas métricas de erro foram empregadas, além de análises gráficas de qualidade de ajuste, incluindo *CURE Plot*. Diferentes medidas são passíveis de utilização para avaliação dos modelos e devem ser escolhidas (com devido embasamento) pelo modelador, no entanto, é essencial o emprego mínimo de métricas capazes de aferir o erro das previsões (absoluto quando se tratar da mesma ordem de grandeza e relativo quando houver comparação entre diferentes ordens de grandeza) e ainda, o comportamento dos resíduos.

Os resultados revelaram valores de erros sensivelmente inferiores dos modelos de RNA quando comparados aos modelos MVPLN, para acidentes sem vítimas, em quase todos os quarenta modelos iniciais. No caso de acidentes com vítimas e com mortes, os modelos MVPLN performam ligeiramente melhor na maioria dos casos. A tendência das medidas de qualidade de ajuste é convergente em ambas as pistas e períodos de tempo. Para o mesmo cenário (pista, extensão de segmento e período de tempo), o comportamento resultante do emprego de RNA e de MVPLN é similar, o que corrobora para a suposição de que os achados do estudo são mais associados aos dados e fenômeno do que à técnica empregada.

Em termos de qualidade de ajuste e análise de resíduos, os resultados auferidos permitiram concluir que todos os modelos com extensão de segmento de 500 m, 1 km e 1,5 km eram inválidos, apresentando vieses e inadequações sistemáticas. Notou-se, entretanto, que em todos os casos a clara tendência de melhoria de desempenho à medida que os segmentos se tornam mais extensos até o segmento de extensão “ideal”.

Vale a ressalva de que, em nenhuma abordagem a previsão do número de acidentes com mortes foi razoável, inclusive associando-se outras técnicas para esse tipo de modelagem. Essa constatação era esperada já que apenas os fatores viário-ambientais, operacionais e de pavimento não são eficientes para prever a ocorrência desse tipo de acidente. A ocorrência de um acidente que resulte numa vítima fatal extrapola as questões de engenharia e centra-se em aspectos humanos, veiculares e características específicas do acidente. Ainda assim, quando não se dispõe de outra possibilidade, a utilização da proporção entre os níveis de severidade de



acidentes (pirâmide de Hydén) a partir de previsões acuradas de acidentes sem vítimas e com vítimas pode fornecer uma estimativa da ocorrência de acidentes fatais.

A análise conjunta das medidas de erros e gráficos de qualidade de ajuste permitiu selecionar o melhor modelo para cada pista e período de tempo. Nesse sentido, constatações interessantes foram feitas. Para a Pista Norte, tanto para a abordagem com RNA quanto com MVPLN e, para os dois períodos de tempo, a extensão de segmento que conduziu ao melhor desempenho foi de 3,5 km e para a Pista Sul, de 4 km. Isso indica que, independente da técnica utilizada e da série histórica analisada, essas extensões são as que efetivamente melhor modelam a ocorrência de acidentes no trecho da rodovia analisada. Na prática, os resultados do presente trabalho sugerem que, a partir de 3,5 km, a extensão do segmento deixa de ser preponderante para a qualidade da previsão dos acidentes. Isso atende ao objetivo específico “*Avaliar a influência da extensão do segmento no processo de modelagem*”.

Em última instância, isso significa que com os dados comumente disponibilizados da operação e fiscalização rodoviária brasileira, com as formas convencionais de medição, o ajuste de modelos é melhor para segmentos mais extensos, cerca de 3,5 km. Destaca-se, outrossim, que essas variáveis explicativas são as comumente referidas e utilizadas em estudos de outros países, o que pode indicar que a recomendação da extensão de segmento pode ser válida não só no contexto brasileiro, mas também em outras realidades com características similares. Além do que, existe uma dificuldade de utilizar de um outro rol de variáveis muito distinto deste, reforçando que talvez seja o comportamento habitual para modelos de previsão de acidentes nessas condições.

Esses resultados convergem com os verificados por Green (2018) que desenvolveu modelos de previsão de acidentes para rodovias de pista dupla americanas e concluiu que a extensão ideal para modelagem era de 2 milhas (3,2 km). Além disso, quando os resultados são comparados aos de outros estudos realizados no contexto rodoviário brasileiro, especificamente Waihrich (2016) e Silva (2017), confirma-se a adequação dos modelos desenvolvidos no presente estudo.

Numa análise geral, a qualidade de ajuste dos modelos de RNA foi ligeiramente superior à dos modelos estatísticos. E, quando observados apenas os modelos selecionados, a superioridade dos modelos RNA frente aos MVPLN é ainda mais nítida. Ressalte-se, entretanto que, ambas as abordagens conduziram a resultados aceitáveis e modelos válidos. Tais constatações já

confirmam o potencial de utilização dessa técnica de AM para a modelagem de acidentes, especialmente os de resposta multivariada que foi tratado neste trabalho.

Adicionalmente, refere-se que os gráficos de resíduos e de dados em ordem espacial/temporal revelaram inexistência de autocorrelação nos resíduos para os modelos selecionados, especialmente os de RNA. Diante disso, é de se concluir que os efeitos de possível correlação espacial e/ou temporal dos dados (dados longitudinais) foram adequadamente abordados com o uso das redes neurais. Deste modo, o objetivo específico “*Investigar a adequação do uso de técnica de AM para previsão multivariada de acidentes*” também foi adequadamente contemplado.

A validade preditiva, que analisa a qualidade de ajuste do modelo para dados independentes foi conduzida para os modelos de RNA selecionados. A avaliação permitiu verificar que, apesar de ter havido um decréscimo de desempenho do conjunto de validação em relação aos dados de treinamento, os modelos mantiveram comportamento aceitável e, portanto, foram tidos como válidos para utilização em previsões.

A terceira vertente de validação, a validade estrutural, analisou o comportamento do modelo em relação ao sistema real simulado. Isso permitiu atender ao terceiro objetivo específico “*Avaliar a interpretabilidade dos modelos quanto aos efeitos das variáveis*”. Especialmente para as redes neurais foram empregadas técnicas de análise de sensibilidade de forma a extrair indiretamente as relações entre as variáveis de entrada e as saídas do modelo. O uso conjunto de quatro métodos (Sobol’, Morris, perfil de sensibilidade e fator de importância) implicou na conclusão de que as variáveis explicativas possuem comportamento não linear com as variáveis resposta e ainda, a variação nas saídas são mais influenciadas pela interação entre os *inputs* do que do efeito direto individual de cada um deles. Da mesma maneira, pôde-se ter como conclusão geral que o uso do solo (*Uso\_solo\_U* e *Uso\_solo\_R*) é o fator menos influente na ocorrência de acidentes enquanto que o volume de tráfego é apontado como importante variável.

O emprego dos métodos de análise de sensibilidade revelou também padrões importantes na relação geral entre as variáveis, mas não conseguiu apontar conclusões mais práticas em termos de cada variável. Entende-se, portanto, esses métodos podem ser úteis, porém devem ser

empregados com cautela por dependerem não somente do problema modelado, mas das amostras utilizadas, do procedimento de execução e das características da rede neural.

De outro lado, os modelos MVPLN tiveram seu comportamento estrutural verificado mediante análise da elasticidade das variáveis. Algumas constatações convergiram para o que tradicionalmente tem se verificado na literatura, enquanto que outras variáveis tiveram comportamento diverso. Em termos de variáveis significativas, *IMA*, *L\_acost*, *N\_faixas*, *N\_acessos*, *QI*, *Div\_pista\_B*, *Div\_pista\_C* e *Uso\_solo\_R* tiveram comportamento consistente, estando sempre associadas ao aumento no número de acidentes. Ao passo que as variáveis *L\_cant*, *PCR*, *IRH*, *V\_max*, *CEV* e *Uso\_solo\_U* associaram-se negativamente aos acidentes. E ainda, *VDMA*, *PCC* e *P\_ilum* tiveram comportamento inconsistente, ora associando-se negativamente e ora positivamente à ocorrência dos acidentes. Em nenhum caso dos quatro modelos as variáveis *IMD* e *N\_saídas* foram tidas como significativas. Ademais, nenhuma variável foi significativa para todos os modelos e mais de um nível de severidade simultaneamente. Essa diferença de significância de variáveis, a depender da variável resposta, é comum em modelos multivariados.

Posteriormente, aplicando a seleção de variáveis *backward* foram obtidos modelos com desempenho bastante similar aos originais, mas com um número bem reduzido de variáveis, de uma a três. Apenas as variáveis *VDMA*, *QI*, *P\_ilum*, *Div\_pista\_B* e *Uso\_solo\_U* figuraram como significativas em algum dos quatro modelos. Os resultados são interessantes, por permitirem a modelagem com poucas variáveis, mas conforme assegura Cafiso *et al.* (2008), os modelos devem ser selecionados pelo seu valor prático para a engenharia, ainda que não tenham alcançado a melhor qualidade ajuste (erros mínimos e comportamento mais desejável dos resíduos).

Uma constatação interessante quando comparados os modelos de RNA e MVPLN é que, o comportamento de algumas variáveis é convergente, como o caso do volume de tráfego (*VMDA*), no entanto, nem sempre as variáveis que são significativas nos modelos estatísticos são importantes nos modelos de aprendizado de máquina. As variáveis relativas ao uso do solo (*Uso\_solo\_R* e *Uso\_solo\_U*) e divisão de pista (*Div\_pista\_B* e *Div\_pista\_C*), que foram constatadas como as menos influentes pelos métodos de análise de sensibilidade, foram observadas como significativas em pelo menos dois modelos MVPLN. Como discutido, isso

pode ser devido a capacidade das RNA capturarem explicitamente as interações entre as variáveis explicativas enquanto que os modelos estatísticos a consideram como independentes.

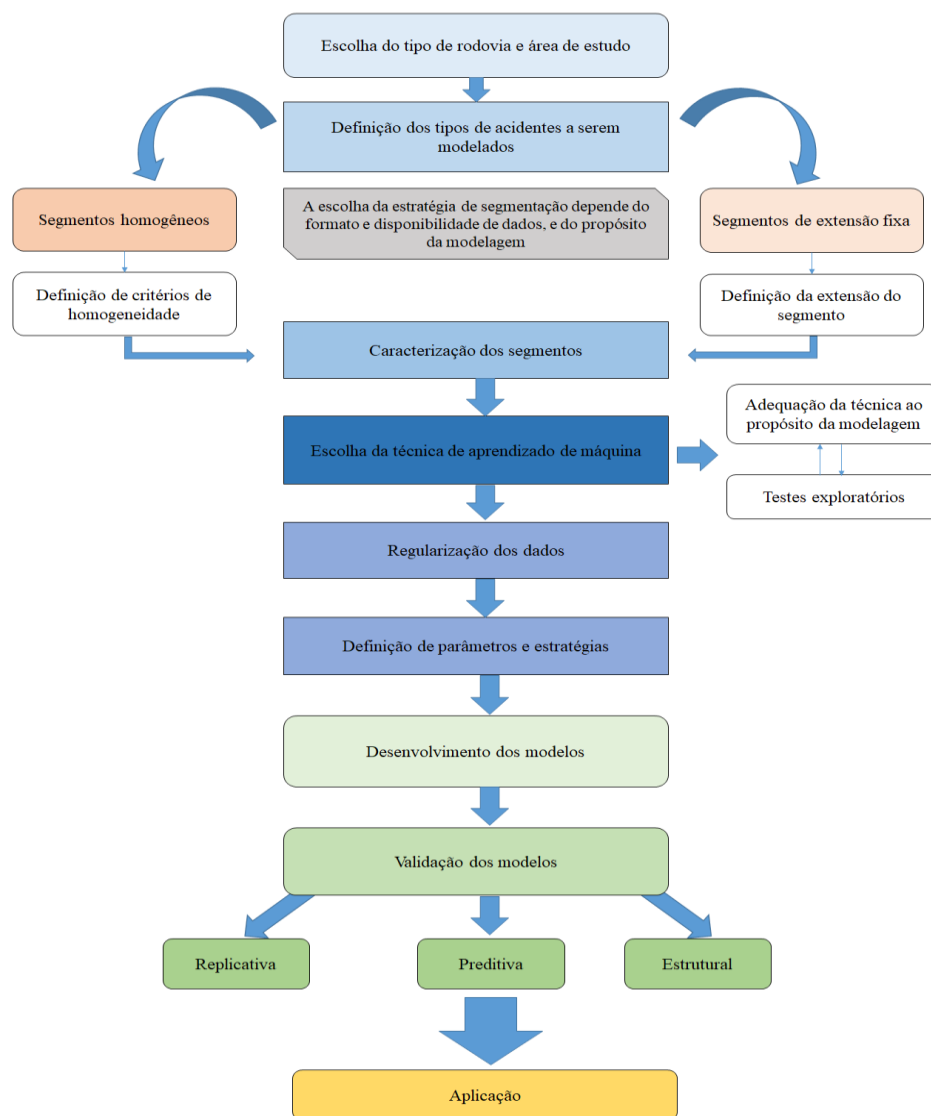
Como é de se notar, mesmo empregando técnicas de análise de sensibilidade, os modelos de RNA não foram capazes de revelar importantes efeitos das variáveis explicativas sobre cada saída do modelo. Por outro lado, os modelos MVPLN forneceram explicitamente as implicações de cada *input* para as saídas e permitiram *insights* acerca das possíveis causas.

Após concluída a avaliação dos modelos desenvolvidos, com vistas a verificar a empregabilidade prática destes para o gerenciamento da segurança viária, fez-se uso dos resultados dos modelos para ranqueamento e identificação de segmentos críticos. Comparando com *rankings* resultantes dos modelos de RNA e MVPLN com o de referência, foi possível verificar a concordância razoável dos 25 segmentos mais bem classificados e ainda, especialmente para redes neurais, eficiência na identificação e priorização dos segmentos críticos. No período 2011-2014, por exemplo, tanto para Pista Sul quanto para Pista Norte, todos os segmentos críticos prioritários foram adequadamente identificados pelos modelos de RNA. Diante da exploração realizada, deu-se por atendido o último objetivo específico do trabalho “*Investigar a aplicabilidade dos modelos desenvolvidos para ranqueamento e identificação de segmentos críticos*”.

Finalmente, aponta-se que os modelos de RNA possuem validade replicativa e preditiva, sendo capazes de ajustar-se bem aos dados de treinamento e, mediante aprendizado adquirido, fazer previsões razoáveis a partir de dados desconhecidos. Os modelos MVPLN, em contrapartida, não permitem a validade preditiva, mas possibilitam a avaliação explícita dos efeitos de cada variável explicativa sobre a saída do modelo, o que é uma limitação para os modelos de redes neurais. De um lado, têm-se a flexibilidade e disponibilidade de diversas plataformas e *softwares* para manipulação de dados, alteração de parâmetros e modelagem com redes neurais. De outro, tem-se um ambiente computacional mais restrito e pouco flexível quanto a alteração de dados (formato muito específico de arquivos, divergindo do usado na análise de dados) e condução da modelagem para o caso dos modelos MVPLN. Como característica de simulação de Monte Carlo, milhares de execuções devem ser executadas para convergência dos resultados, o que implica normalmente em um custo computacional e tempo de execução bem superior que o tido com RNA.

É, portanto, patente que ambas as abordagens têm vantagens e limitações. A decisão por utilização de uma ou outra depende do propósito da modelagem, especialmente se vocacionada apenas para previsão de frequência de acidentes ou para identificação de fatores contribuintes para ocorrência de tais eventos. Não obstante, recordando do paradigma viés-variância, vê-se que o uso conjunto das abordagens estatística e de aprendizado de máquina para modelagem do problema é bastante promissora.

Ao final desse trabalho, acredita-se que a pergunta “*Como desenvolver modelos de previsão de acidentes para rodovias com uso de técnicas de aprendizado de máquina?*” Pode ser respondida por meio do fluxograma proposto na Figura 8.2.



**Figura 8.2** – Procedimento geral para desenvolvimento de modelos de previsão de acidentes em rodovias com o uso de técnica de aprendizado de máquina

### **8.3.LIMITAÇÕES**

Uma limitação do estudo foi a não utilização dos dados de velocidade operacional, uma vez que não era disponível e de difícil coleta no extenso trecho em análise, pois não é, no Brasil, uma variável produzida das atividades de operação rodoviária. Nesse sentido, o volume de tráfego classificado não foi disponibilizado, o que poderia ter sido utilizado para revelar a influência do volume de veículos pesados para a ocorrência dos acidentes. Além disso, mais pontos de medição do volume de tráfego são desejáveis.

Outra limitação diz respeito a precisão do registro de acidente, uma vez que foram registrados com referência ao marco quilométrico. A partir de 2018, algumas concessionárias reguladas pela ANTT passaram a proceder ao registro por meio de coordenadas geográficas, o que certamente facilitará as análises de acidentes e irá conferir maior confiabilidade a elas.

Intentou-se incorporar variáveis relativas à sinalização no processo de modelagem, no entanto, os dados relativos à sinalização horizontal e vertical da rodovia eram disponíveis apenas para alguns anos da série histórica analisada.

Características detalhadas do traçado geométrico da rodovia não foram utilizadas neste estudo uma vez que, conforme alegado pelos órgãos competentes, o projeto da rodovia não foi localizado. Os principais atributos do traçado (comprimentos de tangentes e curvas, inclinações e raios de curva horizontal) foram obtidos mediante inspeção em campo e reconstituição do traçado.

A exploração inicial, limpeza e verificação das bases de dados revelou existir inconsistências no registro de alguns acidentes. Mesmo que essa inspeção detalhada tenha sido realizada, descartando os dados espúrios, entende-se que deve haver maior rigor e controle das concessionárias e da agência reguladora para garantir a fiabilidade dos registros.

### **8.4. RECOMENDAÇÕES**

Com base nas constatações do estudo e oportunidades de avanços, são feitas as seguintes recomendações para novos estudos:

- Desenvolvimento de um sistema especialista para segmentação de rodovias segundo diferentes critérios. O processo automático de segmentação da rodovia facilitará o desenvolvimento da modelagem, permitindo avaliar o ajuste das diferentes formas de segmentação e reduzir substancialmente o tempo da etapa mais morosa do desenvolvimento dos modelos;
- Aplicação do procedimento aqui desenvolvido em outros trechos de rodovia, com diferentes características. Embora o estudo tenha sido conduzido num trecho relativamente extenso de rodovia, a execução de procedimento similar em outros trechos irá permitir avaliar a convergência das constatações aqui verificadas;
- Desenvolvimento de estratégia multivariada para redução do número de variáveis, tanto para RNA quanto para MVPLN. Os métodos mais comuns de seleção de variáveis são aplicáveis diretamente a problemas de resposta univariada, carecendo, entretanto, de adaptação ao problema multivariado;
- Associação de análise de *cluster* ao processo de modelagem. A utilização de técnica de agrupamento nos procedimentos iniciais da modelagem, antes do emprego de RNA, pode contribuir para otimização dos resultados e descoberta de padrões interessantes;
- Desenvolvimento de modelos multivariados por tipo de acidente. Se valer da abordagem multivariada proposta aqui para desenvolver modelos de previsão de acidentes segundo diferentes tipos de acidente (colisão traseira, colisão frontal, saída de pista, capotamento, etc.).

## REFERÊNCIAS BIBLIOGRÁFICAS

- AASHTO (2010) American Association of State and Highway Transportation Officials. *Highway Safety Manual*. Washington, USA.
- ABDEL-ATY, M. A., & RADWAN, A. E. (2000) Modeling traffic accident occurrence and involvement. *Accident Analysis and Prevention*, v. 32, p. 633-642.
- ABDEL-ATY, M. A. & ABDELWAHAB, H. T. (2004) Predicting Injury Severity Levels in Traffic Crashes: A Modeling Comparison. *Journal of Transportation Engineering*, v. 130, p. 204-210.
- ABDELWAHAB, H. & ABDEL-ATY, M. (2001) Development of Artificial Neural Network Models to Predict Driver Injury Severity in Traffic Accidents at Signalized Intersections. *Transportation Research Record*, n. 1746, p. 6-13.
- ABELLÁN, J., LÓPEZ, G. & OÑA, J. (2013) Analysis of traffic accident severity using Decision Rules via Decision Trees. *Expert Systems with Applications*, v. 40, p. 6047-6054.
- ABRAHAM, A., PEDREGOSA, F., EICKENBERG, M., GERVAIS, P., MUELLER, A., KOSSAIFI, J., GRAMFORT, A., THIRION, B. & VAROQUAUX, G. (2014) Machine learning for neuroimaging with scikit-learn. *Frontiers in Neuroinformatics*, v. 8, p. 1-10.
- AGUERO-VALVERDE, J. & JOVANIS, P. P. (2009) Bayesian multivariate Poisson lognormal models for crash severity modeling and site ranking. *Transportation Research Record*, n. 2136, p. 82-91.
- AGUERO-VALVERDE, J., WU, K.-F. (KEN) & DONNELL, E. T. (2016) A multivariate spatial crash frequency model for identifying sites with promise based on crash types. *Accident Analysis and Prevention*, v. 87, p. 8-16.
- AKÇAY, S., KUNDEGORSKI, M. E., DEVEREUX, M. & BRECKON, T. P. (2016) Transfer Learning using Convolutional Neural Networks for Object Classification within X-ray Baggage Security Imagery. *Proceedings of the 2016 IEEE International Conference on Image Processing (ICIP)*, Phoenix, USA, p. 1057-1061.
- ALIKHANI, M., NEDAIE, A. & AHMADVAND, A. (2013) Presentation of clustering-classification heuristic method for improvement accuracy in classification of severity of road accidents in Iran. *Safety Science*, v. 60, p. 142-150.
- ALVES, J. C. L. (2012) *Máquina de Vetores de Suporte aplicada a dados de espectroscopia NIR de combustíveis e lubrificantes para o desenvolvimento de modelos de regressão e classificação*. Tese de Doutorado em Ciências, Instituto de Química, Universidade de Campinas, Campinas.
- AMC (2004) Autarquia Municipal de Trânsito, Cidadania e Serviços Públicos de Fortaleza. *Análise de segurança viária com a utilização do SIAT-FOR*. Fortaleza. 96 p.



- AN, G. (1996) The effects of adding noise during backpropagation training on a generalization performance. *Neural Computation*, v. 8, p. 643–674.
- ANTT (2014) Agência Nacional de Transportes Terrestres. *Rodovias federais concedidas: relatório 2013*. Brasília. 322 p.
- ANTT (2019) Agência Nacional de Transportes Terrestres. *Relatório Técnico-Operacional Físico-Financeiro (RETOFF) dos anos 2011, 2012, 2013, 2014, 2015, 2016, 2017 e 2018*. Brasília.
- AZEVÊDO, L. L. A. (2018) *Métodos estatísticos em Aprendizado de Máquinas para problemas de Classificação*. Dissertação de Mestrado em Estatística, Departamento de Estatística, Universidade de Brasília.
- AZIZPOUR, H., RAZAVIAN, A. S., SULLIVAN, J., MAKI, A. & CARLSSON, S. (2015) From generic to specific deep representations for visual recognition. *Proceedings 2015 IEEE Conference on Computer Vision and Pattern Recognition*, Boston, USA, p. 36–45.
- BADRINARAYANAN, A. K. V. & CIPOLLA, R. (2016) *Segnet: A deep convolutional encoder-decoder architecture for image segmentation*. arXiv:1511.00561 [cs.CV].
- BALBO, J. T. (2007) *Pavimentação Asfáltica: materiais, projetos e restauração*. São Paulo: Oficina de Textos, 560 p.
- BAMZAI, R., LEE, Y. & LI, Z. (2011) *SAFETY IMPACTS OF HIGHWAY SHOULDER ATTRIBUTES IN ILLINOIS*. Research Report ICT-11-078, Illinois Center for Transportation, Rantoul, USA.
- BARELLA, R. M. (2008) *Contribuição para a avaliação da irregularidade longitudinal de pavimentos com perfilômetros inerciais*. Tese de Doutorado em Engenharia de Transportes, Departamento de Engenharia de Transportes, Universidade de São Paulo, São Paulo.
- BASGALUPP, M. P. (2010) *LEGAL-Tree: Um algoritmo genético multi-objetivo lexicográfico para indução de árvores de decisão*. Tese de Doutorado em Ciências de Computação e Matemática Computacional, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos.
- BATES, D. M. & WATTS, D. G. (1988) *Nonlinear Regression Analysis and its Applications*. John Wiley & Sons, Hoboken, USA, 365 p.
- BAUER, K. M. & HARWOOD, D. W. (2014) *Safety Effects of Horizontal Curve and Grade Combinations on Rural Two-Lane Highways*. Report FHWA-HRT-13-077, Federal Highway Administration, Washington, USA.
- BECK, M. W. (2018) NeuralNetTools: Visualization and Analysis Tools for Neural Networks. *Journal of Statistical Software*, v. 85(11), p. 1-20.
- BELLA, F., D'AMICO, F. & FERRANTI, L. (2011) Analysis of the effects of pavement defects on safety of powered two wheelers. *Proceedings of 5th International Conference Bituminous Mixtures and Pavements*, Thessaloniki, Greece.

- BENNETT, N. D., CROKE, B. F. W., GUARISO, G., GUILLAUME, J. H. A., HAMILTON, S. H., JAKEMAN, A. J., MARSILI-LIBELLI, S., NEWHAM, L. T. H., NORTON, J. P., PERRIN, C., PIERCE, S. A., ROBSON, B., SEPPELT, R., VOINOV, A. A., FATH, B. D. & ANDREASSIAN, V., (2013) Characterising performance of environmental models. *Environmental Modelling & Software*, v. 40, p. 1-20.
- BERNUCCI, L. B., MOTTA, L. M. G., CERATTI, J. A. P. & SOARES, J. B. (2008) Pavimentação asfáltica – Formação básica para engenheiros. PETROBRAS/ABEDA, Rio de Janeiro, 504 p.
- BEVEN, K. J. & FREER, J. (2001) Equifinality, data assimilation, and uncertainty estimation in mechanistic modelling of complex environmental systems using the GLUE methodology. *Journal of Hydrology*, v. 249, p. 11-29.
- BÍL, M., ANDRÁSIK, R & SEDONÍK, J. (2019) Which curves are dangerous? A network-wide analysis of traffic crash and infrastructure data. *Transportation Research Part A*, v. 120, p. 252-260.
- BILL, J. A. (2015) *An Empirical Analysis of Predictive Machine Learning Algorithms on High-Dimensional Microarray Cancer Data*. Dissertação de Mestrado, Center for Quality & Applied Statistics, Rochester Institute of Technology, Rochester, USA.
- BINDRA, S., IVAN, J. N. & JONSSON, T. (2009) Predicting Segment-Intersection Crashes with Land Development Data. *Transportation Research Record*, n. 2102, p. 9–17.
- BIONDI, D., FRENI, G., IACOBELLIS, V., MASCARO, G. & MONTANARI, A. (2012) Validation of hydrological models: conceptual basis, methodological approaches and a proposal for a code of practice. *Physics and Chemistry of the Earth, Parts A/B/C*, v. 4244, p. 70-76.
- BIRD, F. E. & GERMAIN, G. L. (1966) *Damage Control*. American Management Assoc. Inc., New York, USA, 176 p.
- BOFFO, G. H. (2011) *Formatos e técnicas de modelos de previsão de acidentes de trânsito*. Dissertação de Mestrado em Engenharia de Produção, Departamento de Engenharia de Produção, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- BOODLAL, L., DONNELL, E. T., PORTER, R. J., GARIMELLA, D., LE, T., CROSHAW, K., HIMES, S., KULIS, P. & WOOD J. (2015) *Factors Influencing Operating Speeds and Safety on Rural and Suburban Roads*. Report FHWA-HRT-15-030, Federal Highway Administration, Washington, USA.
- BORGES JUNIOR, S. R. (2016) *Sensembles – uma abordagem para melhorar a qualidade das correspondências de instâncias disjuntas em estudos observacionais explorando características idênticas e ensembles de regressores*. Tese de Doutorado em Ciência da Computação, Centro de Ciências Exatas e de Tecnologia, Universidade Federal de São Carlos, São Carlos.
- BORIN, A. (2007) *Aplicações de Máquinas de vetores de suporte por mínimos quadrados (LS-SVM) na quantificação de parâmetros de qualidade de matrizes lácteas*. Tese de Doutorado em Ciências, Instituto de Química, Universidade Estadual de Campinas, Campinas.

- BORSOS, A., JOHN, N. I., GYULA, O. (2014) Development of safety performance functions for two-lane rural first-class main roads in Hungary. *Proceedings of 5th Transport Research Arena Conference*, Paris, France.
- BOTERO, E. M. (2018) *Metodologia para aplicação de redes neurais artificiais para sistemas de alerta de escorregamentos deflagrados por chuvas em regiões montanhosas*. Tese de Doutorado em Geotecnia, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília.
- BOX, G. E. P., JENKINS, G., REINSEL, G. C. & LJUNG, G. M. (2015) *Time Series Analysis: Forecasting and Control*. 5th ed. John Wiley and Sons Inc., Hoboken, USA, 712 p.
- BRAGA, A. P., CARVALHO, A. P. L. F. & LUDERMIR, T. B. (2011) *Redes neurais artificiais: teoria e aplicações*. 2 ed. LTC, Rio de Janeiro, Brasil, 226p.
- BRANGER, F., GIRAUDET, L-G., GUIVARCH, C & QUIRION, P. (2015) Global sensitivity analysis of an energy-economy model of the residential building sector. *Environmental Modelling & Software*, v. 70, p. 45–54.
- BREIMAN, L. (2001) Statistical modeling: The two cultures. *Statistical Science*, v. 16(3), p. 199-215.
- BREMBILLA, E., HOPFE, C. J. & MARDALJEVIC, J. (2018) Influence of input reflectance values on climate-based daylight metrics using sensitivity analysis. *Journal of Building Performance Simulation*, v. 11(3), p. 333-349.
- BURGES, C. J. C. (1998) A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, v. 2(2), p. 121–167.
- BURMAN, P. (1989) A comparative study of ordinary cross-validation, v-fold cross-validation and repeated learning-testing methods. *Biometrika*, v. 76(3), p. 503–514.
- 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*, v. 5(2), p. 129-136.
- CAFISO, S., DI GRAZIANO, A. & PAPPALARDO, G. (2012) Road safety issues for bus transport management. *Procedia - Social and Behavioral Sciences*, v. 48, p. 2251–2261.
- CAFISO, S., DI GRAZIANO, A., DI SILVESTRO, G., LA CAVA, G. (2008) Safety Performance Indicators for Local Rural Roads: Comprehensive Procedure from Low-Cost Data Survey to Accident Prediction Model. *Proceedings of the 87th Annual Meeting of the Transportation Research Board*, Washington, USA.
- CAFISO, S., LA CAVA, G. & MONTELLA, A. (2007) Safety Index for Evaluation of Two Rural Highways. *Transportation Research Record*, n. 2019, p. 136-145.
- CAFISO, S., DI GRAZIANO, A., DI SILVESTRO, G., LA CAVAA, G. & PERSAUD, B. (2010) Development of comprehensive accident models for two-lane rural highways using exposure, geometry, consistency and context variables. *Accident Analysis and Prevention*, v. 42, p. 1072-1079.

- CAMPOLONGO, F., CARIBONI, J. & SALTELLI, A. (2007) An effective screening design for sensitivity analysis of large models. *Environmental Modelling & Software*, v. 22(10), p. 1509–1518.
- CARDOSO, J. L. (1998) *Models on the relations between workload, speed variation, road characteristics and accident frequencies*. Relatório Técnico, Laboratório Nacional de Engenharia Civil, Lisboa, Portugal.
- CARLIN, B. P. & LOUIS, T. A. (1996) *Bayes and Empirical Bayes Methods for Data Analysis*. Chapman and Hall, London, UK, 440 p.
- CARSON, J. & MANNERING, F. (2001) The effect of ice warning signs on ice-accident frequencies and severities. *Accident Analysis and Prevention*, v. 33(1), p. 99–109.
- CASTELLÓ, D. L. (2017) *Desenvolvimento de uma metodologia para o traçado e melhoria de rodovias convencionais a partir da análise de segurança viária mediante modelos de consistência* (em Espanhol). Tese de Doutorado, Departamento de Ingeniería e Infraestructura de los Transportes, Universitat Politècnica de València, València, Espanha.
- CASTREJON, L., AYTAR, Y., VONDRICK, C., PIRSIYAVASH, H. & TORRALBA, A. (2016) Learning aligned cross-modal representations from weakly aligned data. *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, USA, p. 2940–2949.
- CEFTRU (2002) Centro Interdisciplinar de Estudos em Transportes – Universidade de Brasília. *Procedimentos para o tratamento de locais críticos de acidentes de trânsito*. TDA Desenho e Arte. Brasília. 75 p.
- CENEK, P. D., DAVIES, R. B., McLARIN, M. W. (1997) *Road Environment and Traffic Crashes*. Research Report 79, Transfund New Zealand, Wellington, New Zealand.
- CEREZO, V. & CONCHE, F. (2016) Risk assessment in ramps for heavy vehicles – A French study. *Accident Analysis and Prevention*, v. 91, p. 183-189.
- CHANG, G. & XIANG, H. (2003) *The relationship between congestion levels and accidents*. Report, Maryland State Highway Administration, Baltimore, USA.
- CHANG, J. C. & HANNA, S. R. (2004) Air quality model performance evaluation. *Meteorology and Atmospheric Physics*, v. 87, p. 167-196.
- CHANG, L. (2005) Analysis of freeway accident frequencies: negative binomial regression versus artificial neural network. *Safety Science*, v. 43, p. 541-557.
- CHANG, L. & CHEN, W. (2005) Data mining of tree-based models to analyze freeway accident frequency. *Journal of Safety Research*, v. 36, p. 365-375.
- CHANG, L. & WANG, H. (2006) Analysis of traffic injury severity: An application of non-parametric classification tree techniques. *Accident Analysis and Prevention*, v. 38, p. 1019-1027.

- CHAPELLE, O., SCHÖLKOPF, B., ZIEN, A. (2006) *Semi-supervised learning*. MIT Press, Cambridge, 528 p.
- CHAPMAN, P., CLINTON, J., KERBER, R., KHABAZA, T., REINARTZ, T., SHEARER, C., WIRTH, R. (2000) *CRISP-DM 1.0 Step-by-step data mining guide*. Technical Report, SPSS Inc., Chicago, USA.
- CHAPRA, S. C. (1997) *Surface Water Quality Modeling*. McGraw-Hill, New York, USA, 844 p.
- CHEN, C., ZHANG, G., QIAN, Z., TAREFDER, R. A. & TIAN, Z. (2016) Investigating driver injury severity patterns in rollover crashes using support vector machine models. *Accident Analysis and Prevention*, v. 90, p. 128-139.
- CHEN, S. H. (2010) *Mining patterns and factors contributing to crash severity on road curves*. Tese de Doutorado, School of Psychology and Counselling, Queensland University of Technology, Queensland, Australia.
- CHENG, W., GILL, G. S., DASU, R., XIE, M., JIA, X. & ZHOU, J. (2017) Comparison of Multivariate Poisson lognormal spatial and temporal crash models to identify hot spots of intersections based on crash types. *Accident Analysis and Prevention*, v. 99, p. 330-341.
- ÇODUR, M. Y. & TORTUM, A. (2015) An artificial neural network model for highway accident prediction: a case study of Erzurum, Turkey. *Promet – Traffic&Transportation*, v. 27(3), p. 217-225.
- CONGDON, P. (2003) *Bayesian Statistical Modeling*. John Wiley & Sons, West Sussex, UK, 596 p.
- COOK, D., REGINALD, S. & JUSTIN, J. (2011) Effect of Road Segmentation on Highway Safety Analysis. *Proceedings of the 90th Annual Meeting of the Transportation Research Board*, Washington, USA.
- COSTA, J. O. (2013) *Desenvolvimento dum modelo de previsão de acidentes*. Tese de Doutoramento em Segurança Rodoviária, Escola de Engenharia, Universidade do Minho, Guimarães, Portugal.
- COUTO, A. & FERREIRA, S. (2011) A note on modeling road accident frequency: A flexible elasticity model. *Accident Analysis and Prevention*, v. 43, p. 2104-2111.
- CRONBACH, L. J. (1971) *Test Validation*. Educational Measurement. 2nd ed., R. L. Thorndike (ed.), American Council on Education, Washington, USA, p. 443–507.
- CROUT, N., KOKKONEN, T., JAKEMAN, A. J., NORTON, J. P., NEWHAM, L. T. H., ANDERSON, R., ASSAF, H., CROKE, B. F. W., GABER, N., GIBBONS, J., HOLZWORTH, D., MYSIAK, J., REICHL, J., SEPPELT, R., WAGENER, T. & WHITFIELD, P. (2008) *Good modelling practice*. Developments in Integrated Environmental Assessment, A. J. Jakeman, A. A. Voinov, A. E. Rizzoli & S. H. Chen (eds.), Elsevier, Amsterdam, Netherlands, p. 15-31.

- DAS, A. & ABDEL-ATY, M. (2010) A genetic programming approach to explore the crash severity on multi-lane roads. *Accident Analysis and Prevention*, v. 42, p. 548-557.
- DAS, A. & ABDEL-ATY, M. (2011) A combined frequency-severity approach for the analysis of rear-end crashes on urban arterials. *Safety Science*, v. 49, p. 1156-1163.
- DASH, C. S. K., BEHERA, A. K., DEHURI, S. & CHO, S-B (2016) Radial basis function neural networks: a topical state-of-the-art survey. *Open Computer Science*, v. 6, p. 33-63.
- DATASUS (2017) Departamento de Informática do SUS. Disponível em: <http://datasus.saude.gov.br/>. Acesso em 27 abr. 2017.
- DAVIS, G. A. (2008) *Cross Median Crashes: Identification and Countermeasures*. Report MC/RC 2008-17, Minnesota Department of Transportation, St. Paul, USA.
- DECKER, K. M., FOCARDI, S. (1995) *Technology overview: A report on data mining*. Technical Report CSCS TR-95-02, CSCS-ETH, Swiss Scientific Computing Center, Lugano, Switzerland.
- DELEN, D., SHARDA, R. & BESSONOV, M. (2006) Identifying significant predictors of injury severity in traffic accidents using a series of artificial neural networks. *Accident Analysis and Prevention*, v. 38(3), p. 434-444.
- DENATRAN (1987) Departamento Nacional de Trânsito. *Manual de identificação, análise e tratamento de pontos negros*. 2ª edição. Brasília. 127 p.
- DIETTERICH, T. G. (2000) Ensemble methods in machine learning. *Multiple Classifier Systems Lecture Notes in Computer Science*, v. 1857, p. 1–15.
- DNER (1985) Departamento Nacional de Estradas de Rodagem. *Projeto de Restauração de Pavimentos Flexíveis e Semi-rígidos*. Publicação DNER-PRO 159/85. Rio de Janeiro. 31p.
- DNER (1986a) Departamento Nacional de Estradas de Rodagem. *Método de Nível e Mira para Calibração de Sistemas Medidores de Irregularidade Tipo Resposta*. Publicação DNER-ES 173/86. Rio de Janeiro. 13 p.
- DNER (1986b) Departamento Nacional de Estradas de Rodagem. *Um Modelo para Identificação de Segmentos Críticos de uma Rede de Rodovias*. Rio de Janeiro.
- DNIT (2006) Departamento Nacional de Infraestrutura de Transportes. *Manual de restauração de pavimentos asfálticos*. Publicação 720 Instituto de Pesquisas Rodoviárias. Rio de Janeiro. 310p.
- DNIT (1999) Departamento Nacional de Infraestrutura de Transportes. *Manual de Projeto Geométrico de Rodovias Rurais*. Publicação 706/20 Instituto de Pesquisas Rodoviárias. Rio de Janeiro. 195 p.
- DNIT e UFSC (2009) Departamento Nacional de Infraestrutura de Transportes e Universidade Federal de Santa Catarina. *Metodologia para identificação de segmentos críticos*.

- Produto 01 do Destaque Orçamentário - Portaria nº 1.282 de 31 de outubro de 2008 - DNIT / UFSC. Brasília. 68 p.
- DNIT e UFSC (2010) Departamento Nacional de Infraestrutura de Transportes e Universidade Federal de Santa Catarina. *Identificação e Priorização de Segmentos Críticos para Estudos de Intervenção*. Produto Adicional do Destaque Orçamentário - Portaria nº 1.282 de 31 de outubro de 2008 - DNIT / UFSC. Brasília. 73 p.
- EL-BASYOUNY, K. & SAYED, T. (2009) Collision prediction models using multivariate Poisson lognormal regression. *Accident Analysis and Prevention*, v. 41(4), p. 820–828.
- ELVIK, R. (1995) Meta-analysis of Evaluations of Public Lighting as Accident Countermeasure. *Transportation Research Record*, n. 1485, p. 112–123.
- ELVIK, R. (2009) *The power model of the relationship between speed and road safety*. Update and new analyses. Report 1034/2009, Institute of Transport Economics, Oslo, Denmark.
- ELVIK, R. (2011) Assessing causality in multivariate accident models. *Accident Analysis and Prevention*, v. 43(1), p. 253-264.
- ELVIK, R. & VAA, T. (2004) *The Handbook of Road Safety Measures*. Elsevier Science, Oxford, UK, p. 1078.
- FACURE, M. (2017) *Funções de ativação – Entendendo a importância da ativação correta nas redes neurais*. Disponível em: <https://matheusfacure.github.io/2017/07/12/activ-func/>. Acesso em 15 de ago. 2019.
- FDOT (2014) *MEDIAN HANDBOOK*. Report, Florida Department of Transportation, Tallahassee, USA.
- FISH, K. E. & BLODGETT, J. G. (2003) A visual method for determining variable importance in an artificial neural network model: an empirical benchmark study. *Journal of Targeting Measurement and Analysis for Marketing*, v. 11(3), p. 244–254.
- FITZPATRICK, K., ELEFTERIADOU, L., HARWOOD, D., COLLINS, J., McFADDEN, J., ANDERSON, I., KRAMES, R., IRIZARRY, N., PARMA, K., BAUER, K. & PASSETTI, K. (2000) *Speed prediction for two-lane rural highways*. Report nº 99-171, Federal Highway Administration, Washington, USA.
- FLOREANO, D., MATTIUSSI, C. (2008) *Bio-inspired artificial intelligence: theories, methods, and technologies*. The MIT Press, Cambridge, UK, 674 p.
- FRAMARIM, C. S. (2003) *Procedimento para monitorar medidas voltadas à redução dos acidentes no sistema viário*. Dissertação de mestrado em Engenharia de Produção, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- FREITAS, E. F., MARTINS, F. F., OLIVEIRA, A., SEGUNDO, I. R. & TORRES, H. (2018) Traffic noise and pavement distresses: Modelling and assessment of input parameters influence through data mining techniques. *Applied Acoustics*, v. 138, p. 147-155.
- FRIDSTROM, L., IFVER, J., INGERBRIGSTEN, 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 and Prevention*, v. 27(1), p. 1-20.
- FRIEDMAN, J. H. (2001) Greedy function approximation: a gradient boosting machine. *The Annals of Statistics*, v. 29(5), p. 1189-1232.
- GAO Y. & GAO, F. (2010) Edited AdaBoost by weighted KNN. *Neurocomputing*, v. 73(16), p. 3079-3088.
- GASS, S. I. (1983) Decision-aiding models: validation, assessment, and related issues for policy analysis. *Operations Research*, v. 31, p. 603-631.
- GELMAN, A., CARLIN, J., STERN, H. S. & RUBIN, D. B. (2003) Bayesian Data Analysis. 2nd ed. Chapman & Hall/CRC, Boca Raton, USA, 675 p.
- GEVREY, M., DIMOPOULOS, I. & LEK, S. (2003) Review and comparison of methods to study the contribution of variables in artificial neural network models. *Ecological Modelling*, v. 160, p. 249-264.
- GITELMAN, V., DOVEH, E., CARMEL, R. & HAKKERT, S. (2019) The influence of shoulder characteristics on the safety level of two-lane roads: A case-study. *Accident Analysis and Prevention*, v. 122, p. 108-118.
- GLENNON, J. C. (1987) Effect of Alignment on Highway Safety. State of the Art Report 6 – Relationships between Safety and Key Highway Features. *Proceedings of the 66th Annual Meeting of the Transportation Research Board*, Washington, USA.
- GLOROT, X., BORDES, A. & BENGIO, Y. (2011) Deep sparse rectifier neural networks. *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics*, Ft. Lauderdale, USA, v. 15, p. 315–323.
- GOODFELLOW, I., BENGIO, Y. & COURVILLE, A. (2016) Deep Learning. MIT Press, Cambridge, UK, 800 p.
- GRAVES A. (2012) Supervised sequence labelling with recurrent neural networks. Springer, Heidelberg, Germany, 146 p.
- GREEN, E. R. (2018) *Segmentation strategies for road safety analysis*. Tese de Doutorado, Department of Civil Engineering, University of Kentucky, Lexington, USA.
- GREEN, E. R. & AGENT, K. R. (2011) Evaluation of the Locations of Kentucky's Traffic Crash Data. *Proceedings of the 3rd International Conference on Road Safety and Simulation*, Indianapolis, USA.
- GREEN, E., NIKIFOROS, S. & REGINALD, S. (2017) Segment Length and Highway Safety Analysis: Does It Matter?. *Proceedings of the 96th Annual Meeting of the Transportation Research Board*, Washington, USA.
- HASHEMI, R., BLANC, L., RUCKS, C. & SHEARRY, A. (1995) Neural Network for Transportation Safety Modeling. *Expert Systems with Applications*, v. 9, p. 247–256.



- HAUER E. (1999) Safety and the choice of degree of curve. *Transportation Research Record*, n. 1665, p. 22-27.
- HAUER, E. (1997) *Observational Before-After Studies in Road Safety*. Emerald Group Publishing Limited, Bingley, UK, 306 p.
- HAUER, E. (2004) Statistical Road Safety Modeling. *Transportation Research Record*, n. 1897, p. 81-87.
- HAUER, E. (2015) *The art of regression modeling in road safety*. Springer, Cham, Switzerland, 252 p.
- HAUER, E. AND BAMFO, J. (1997) Two tools for finding what function links the dependent variable to the explanatory variables. *Proceedings of the 9th International Co-operation on Concepts and Theories (ICTCT) Conference*, Lund, Netherlands.
- HAUER, E., COUNCIL, F. & MOHAMMEDSHAD, Y. (2004) Safety models for urban four-lane undivided road segments. *Transportation Research Record*, n. 1897, p. 96-105.
- HAUSMAN, J. A., HALL, B. & GRILICHES, Z. (1984) Econometric models for count data with an application to the patents - R&D relationship. *Econometrica*, v. 52(4), p. 909-938.
- HAYKIN, S. (1999) *Neural Networks: A Comprehensive Foundation*. 2nd ed. Prentice-Hall, Englewood Cliffs, USA, 842 p.
- HAYKIN, S. (2001) *Redes Neurais: Princípios e prática*. Paulo Martins Engel (Trad.), 2a ed. Bookman, Porto Alegre, Brasil, 898 p.
- HAYKIN, S. (2009) *Neural Networks and Learning Machines*, 3rd ed. PrenticeHall, New York, USA, 906 p.
- HEIBERGER, R. M. & HOLLAND, B. (2004) *Statistical Analysis and Data Display: an Intermediate Course with Examples in S-plus, R, and SAS*. Springer-Verlag, New York, USA, 729 p.
- HOCHREITER, S. & SCHMIDHUBER, J. (1997) Long short-term memory. *Neural computation*, v. 9(8), p. 1735–1780.
- HOLLAND, J. H. (1975) *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor, USA, 232 p.
- HOLMSTRÖM, L. & KOISTINEN, P. (1992) Using additive noise in back-propagation training. *IEEE Transactions on Neural Networks and Learning Systems*, v. 3(1), p. 24-38.
- HOSSEIN, S. A. & ARABANI, M. (2012) The relationship between urban accidents, traffic and geometric design in Tehran. *WIT Transactions on The Built Environment*, v. 128, p. 575-588.
- HOWELL, D. C. (2010) *Statistical methods for Psychology*. 7th ed. Cengage Wadsworth, Canada, 793 p.

- HOWES, P. & CROOK, N. (1999) Using input parameter influences to support the decisions of feedforward neural networks. *Neurocomputing*, v. 24, p. 191–206.
- HU, J. J., LI, F., HAN, B. & YAO, J. (2017) Analysis of the influence on expressway safety of ramps. *Archives of Transport*, v. 43(3), p. 43-51.
- HUANG, H., CHIN, H. & HAQUE, M. (2009) Empirical evaluation of alternative approaches in identifying crash hotspots: naïve ranking, empirical Bayes, and full Bayes methods. *Transportation Research Record*, n. 2103, p. 32–41.
- HUANG, H., ZENG, Q., PEI, X. & WONG, S. C. (2016) Predicting crash frequency using an optimized radial basis function neural network. *Transportmetrica A: Transport Science*, v. 12(4), p. 330-345.
- HUANG, Z., PAN, Z. & LEI, B. (2017) Transfer Learning with Deep Convolutional Neural Network for SAR Target Classification with Limited Labeled Data. *Remote sensing*, v. 9, p. 907-928.
- HUMPHREY, G. B., MAIER, H. R., WU, W., MOUNT, N. J., DANDY, G. C., ABRAHART, R. J. & DAWSON, C. W. (2017) Improved validation framework and R-package for artificial neural network models. *Environmental Modelling & Software*, v. 92, p. 82-106.
- HYDÉN, C. (1987) *The development of a method for traffic safety evaluation: The Swedish traffic conflicts technique*. Bulletin 70, Department of Traffic Planning and Engineering, Lund University, Lund, Sweden.
- ICI (1992) International Commission on Illumination. *Road Lighting as an Accident Countermeasure*. Vienna. Austria.
- IMPRIALOU, M. I. M., QUDDUS, M., PITFIELD, D. E. & LORD, D. (2016) Re-visiting crash-speed relationships: A new perspective in crash modelling. *Accident Analysis and Prevention*, v. 86, p. 173-185.
- IPEA (2015) Instituto de Pesquisa Econômica Aplicada. *Acidentes de Trânsito nas Rodovias Federais Brasileiras: caracterização, tendências e custos para a sociedade*. Relatório de Pesquisa. Brasília. 42 p.
- iRAP (2014) International Road Assessment Programme. *São Paulo Technical Report*. Report. Hampshire, UK.
- ITF (2008) International Transport Forum. *Towards Zero: Ambitious Road Safety Targets and the Safe System Approach*. Research Report, OECD Publishing, Paris, France.
- ITF (2016) International Transport Forum. *Zero Road Deaths and Serious Injuries: Leading a Paradigm Shift to a Safe System*. Research Report, OECD Publishing, Paris, France.
- ITF (2018) International Transport Forum. *Speed and Crash Risk*. Research Report, OECD Publishing, Paris, France.

- IVAN, J. N., WANG, C. & BERNARDO, N. R. (2000) Explaining two-lane highway crash rates using land use and hourly exposure. *Accident Analysis and Prevention*, v. 32, p. 787-795.
- JAMSON, S. L., BENETOU, D. & TATE, F. (2015) The impact of arc visibility on curve negotiation. *Advances in Transportation Studies*, v. 37, p. 79-92.
- JANSEN, M. J. W. (1999) Analysis of variance designs for model output. *Computer Physics Communications*, v. 117, p. 35-43.
- JIANG, Y., ZUR, R. M., PESCE, L. L. & DRUKKER, K. (2009) A Study of the Effect of Noise Injection on the Training of Artificial Neural Networks. *Proceedings of 2009 International Joint Conference on Neural Networks*, Atlanta, p. 1428-1432.
- JONATHAN, A., WU, V., DONNELL, K. F. K. & DONNELL, E. T. (2016) A multivariate spatial crash frequency model for identifying sites with promise based on crash types. *Accident Analysis and Prevention*, v. 87, p. 8-16.
- JOSHUA, S. & GARBER, N. (1990) Estimating truck accident rate and involvement using linear and Poisson regression models. *Transportation Planning and Technology*, v. 15, p. 41-58.
- JOVANIS, P. P. & CHANG, H. L. (1986) Modeling the relationship of accidents to miles traveled. *Transportation Research Record*, n. 1068, p. 42-51.
- KASHANI, A. T. & MOHAYMANY, A. S. (2011) Analysis of the traffic injury severity on two-lane, two-way rural roads based on classification tree models. *Safety Science*, n. 49, p. 1314-1320.
- KAYA, A., KECELI, A. S., CATAL, C., YALIC, H. Y., TEMUCIN, H. & TEKINERDOGAN, B. (2019) Analysis of transfer learning for deep neural network based plant classification models. *Computers and Electronics in Agriculture*, n. 158, p. 20-29.
- KIM, J.-H (2009) Estimating classification error rate: Repeated cross-validation, repeated hold-out and bootstrap. *Computational Statistics and Data Analysis*, v. 53, p. 3735-3745.
- KIM, D. & WASHINGTON, S. (2006) The significance of endogeneity problems in crash models: An examination of left-turn lanes in intersection crash models. *Accident Analysis and Prevention*, v. 38, p. 1094-1100.
- KINGMA, D. P. & BA, J. (2015) Adam: A method for stochastic optimization. *Proceedings of the 3rd International Conference on Learning Representations*, San Diego, USA, p. 1-15.
- KOCKELMAN, K. M. & KWEON, Y. J. (2002) Driver injury severity: An application of ordered probit models. *Accident Analysis and Prevention*, v. 34(3), p. 313-321.
- KONONOV, J., BAILEY, B. & ALLERY, B. K. (2008) Relationships Between Safety and Both Congestion and Number of Lanes on Urban Freeways. *Transportation Research Record*, n. 2083, p. 26-39.

- KOOREY, G. (2009) Road data aggregation and sectioning considerations for crash analysis. *Transportation Research Record*, n. 2103, p. 61-68.
- KOPPEL, S., BUGEJA, L., SMITH, D., LAMB, A., DWYER, J., FITZHARRIS, M., NEWSTEAD, S., D'ELIA, A. & CHARLTON, J. (2018) Understanding fatal older road user crash circumstances and risk factors. *Traffic Injury Prevention*, v. 19, p. S181-S183.
- KOTU, V. & DESHPANDE, B. (2015) Predictive Analytics and Data Mining: Concepts and Practice with RapidMiner. Morgan Kaufmann, Waltham USA, 446 p.
- KRUSCHKE, J. K. (2015) Doing Bayesian data analysis. A tutorial with R, JAGS, and Stan. 2nd ed. Elsevier Inc., Boston, USA, 749 p.
- KUDRASZOW, N. & VIEU, P. (2013) Uniform consistency of kNN regressor for functional variables. *Statistics and Probability Letters*, v. 83, p. 1863-1870.
- KUNH, M. & JOHNSON, K. (2013) Applied Predictive Modeling. Springer, New York, 600 p.
- KWON, O. H., RHEE, W. & YOON, Y. (2015) Application of classification algorithms for analysis of road safety risk factor dependencies. *Accident Analysis and Prevention*, v. 75, p. 1-15.
- LABI, S. (2006) Effects of Geometric Characteristics of Rural Two-Lane Roads on Safety. Report FHWA/IN/JTRP-2005/2, Federal Highway Administration/Purdue University, West Lafayette, USA.
- LAWRENCE, S., GILES, C. L. & TSOI, A. C. (1997) Lessons in neural network training: Training may be harder than expected. *Proceedings of National Conference on Artificial Intelligence (AAAI-97)*, Menlo Park, USA, p. 540-545.
- LEE, C. & PARK, S. (2011) Damage classification of pipelines underwater flow operation using multi-mode actuated sensing technology. *Smart Materials and Structures*, v. 20, p. 1-9.
- LEE, J., ABDEL-ATY, M. & JIANG, X. (2015) Multivariate crash modeling for motor vehicle and non-motorized modes at the macroscopic level. *Accident Analysis and Prevention*, v. 78, p. 146-154.
- LEK, S., BELAUD, A., DIMOPOULOS, I., LAUGA, J. & MOREAU, J. (1995) Improved estimation, using neural networks, of the food consumption of fish populations. *Marine and Freshwater Research*, v. 46, p. 1229-1236.
- LEK, S., DELACOSTE, M., BARAN, P., DIMOPOULOS, I., LAUGA, J. & AULAGNIER, S. (1996) Application of neural networks to modelling nonlinear relationships in ecology. *Ecological Modelling*, v. 90, p. 39-52.
- LENTO, G. C. (2017) *Random forest em dados desbalanceados: uma aplicação na modelagem de churn em seguro saúde*. Dissertação de Mestrado em Modelagem Matemática da Informação, Escola de Matemática Aplicada, Fundação Getúlio Vargas, Rio de Janeiro.

- LERAY, P. & GALLINARI, P. (1999) Feature selection with neural networks. *Behaviormetrika*, v. 26(1), p. 145-166.
- LI, H., GRAHAM, D. J. & MAJUMDAR, A. (2012) The effects of congestion charging on road traffic casualties: A causal analysis using difference-in-difference estimation. *Accident Analysis and Prevention*, v. 49, p. 366-377.
- LI, X., LORD, D., ZHANG, Y & XIE, Y. (2008) Predicting motor vehicle crashes using support vector machine models. *Accident Analysis and Prevention*, v. 40(4), p. 1611-1618.
- LI, Y. & LIU, F. (2016) *Whiteout: Gaussian adaptive noise injection regularization in deep neural networks*. arXiv:1612.01490 [stat.ML].
- LJUNG, L., CHEN, T. & MU, B. (2019) A shift in paradigm for system identification, *International Journal of Control*, v. 1, p. 1-8.
- LONG, J., SHELHAMER, E. & DARRELL, T. (2015) Fully convolutional networks for semantic segmentation. *Proceedings of the 28th IEEE Conference on Computer Vision and Pattern Recognition*, Boston, USA, p. 3431-3440.
- 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 and Prevention*, v. 40(4), p. 1441-1457.
- LORD, D. (2002) Issues related to the application of accident prediction models for the computation of accident risk on transportation networks. *Transportation Research Record*, n. 1784, p. 17-26.
- LORD, D. & MANNERING, F. (2010) The statistical analysis of crash-frequency data: A review and assessment of methodological alternatives. *Transportation Research Part A*, v. 44, p. 291-305.
- LU, J., ALBERT, G., KIROLOS, H. & WANYANG, W. (2013) Clustering-based roadway segment division for the identification of high-crash locations. *Journal of Transportation Safety & Security*, v. 5(3), p. 224-239.
- LUO, Y., TSENG, H-H., CUI, S., WEI, L., HAKEN, R. K. T. & EL NAQA, I. (2019) Balancing accuracy and interpretability of machine learning approaches for radiation treatment outcomes modeling. *BJR Open*, v. 1(1), p. 1-12.
- LUNN, D., SPIEGELHALTER, D., THOMAS, A. & BEST, N. (2009) The BUGS project: Evolution, critique, and future directions. *Statistics in Medicine*, v. 28, p. 3049-3067.
- MA, J. & KOCKELMAN, K. M. (2006) Bayesian Multivariate Poisson Regression for Models of Injury Count, by Severity. *Transportation Research Record*, n. 1950, p. 24-34.
- MA, J., KOCKELMAN, K. M. & DAMIEN, P. (2008) A multivariate Poisson lognormal regression model for prediction of crash counts by severity, using Bayesian methods. *Accident Analysis and Prevention*, v. 40(3), p. 964-975.
- MA, X., CHEN, S. & CHEN, F. (2017) Multivariate space-time modeling of crash frequencies by injury severity levels. *Analytic Methods in Accident Research*, v. 15, p. 29-40.

- MADALOZO, H. C. (2003) *Desenvolvimento de ferramenta de análise de curvas horizontais de rodovias, para melhoramento de projeto e operação, utilizando redes neurais artificiais*. Dissertação de Mestrado em Construção Civil, Setor de Tecnologia, Universidade Federal do Paraná, Curitiba.
- MAIER, H. R., JAIN, A., DANDY, G. C. & SUDHEER, K. P. (2010) Methods used for the development of neural networks for the prediction of water resource variables in river systems: current status and future directions. *Environmental Modelling & Software*, v. 25, p. 891-909.
- MANNERING, F. L. & BHAT, C. R. (2014) Analytic Methods in Accident Research: Methodological Frontier and Future Directions. *Analytic Methods in Accident Research*, v. 1, p. 1-22.
- MARETTO, D. A. (2011) *Aplicação de máquinas de vetores de suporte para desenvolvimento de modelos de classificação e calibração multivariada em espectroscopia no infravermelho*. Tese de Doutorado em Ciências, Instituto de Química, Universidade Estadual de Campinas, Campinas.
- MARKOPOULOS, A. P., GEORGIPOULOS, S. & MANOLAKOS, D. E. (2016) On the use of back propagation and radial basis function neural networks in surface roughness prediction. *Journal of Industrial Engineering International*, v. 12(3), p. 389-400.
- MARTINO, J. A. (2015) *Algoritmos evolutivos como método para desenvolvimento de projetos de arquitetura*. Tese de Doutorado em Arquitetura, Tecnologia e Cidade, Faculdade de Engenharia Civil, Arquitetura e Urbanismo, Universidade Estadual de Campinas, Campinas.
- MAY, R., DANDY, G. & MAIER, H. (2011) *Review of Input Variable Selection Methods for Artificial Neural Networks*. Artificial Neural Networks – Methodological Advances and Biomedical Applications, K. Suzuki (org.), InTech, Chicago, USA, p. 19-44.
- MCCARTT, A. T., NORTHRUP, V. S. & RETTING, R. A. (2004) Types and characteristics of ramp-related motor vehicle crashes on urban interstate roadways in Northern Virginia. *Journal of Safety Research*, v. 35, p. 107-114.
- MEHTA, P., BUKOV, M., WANG, C-H., DAY, A. G. R., RICHARDSON, C., FISHER, C. K. & SCHWAB, D. J. (2019) A high-bias, low-variance introduction to Machine Learning for physicists. *Physics Reports*, v. 810, p. 1-124.
- MIAOU, S. P. & LUM, H. (1993) Modeling vehicle accidents and highway geometric design relationships. *Accident Analysis and Prevention*, v. 25(6), p. 689–709.
- MIAOU, S. P. & SONG, J. J. (2005) Bayesian ranking of sites for engineering safety improvements: decision parameter, treatability concept, statistical criterion and spatial dependence. *Accident Analysis and Prevention*, v. 37(4), p. 699–720.
- MICHALEWICZ, Z. & FOGEL, D. B. (2004) *How to Solve It: Modern Heuristics*. 2th ed. Springer, New York, USA, 584 p.
- MINSKY, M. & PAPER, S. (1969) *Perceptrons – An Introduction to Computational Geometry*. Cambridge MIT Press, Cambridge, UK, 258 p.

- MITCHELL, T. M. (1997) *Machine Learning*. McGraw-Hill, Maidenhead, UK, 432 p.
- MOLINARO, A. M., SIMON, R. & PFEIFFER, R. M. (2005) Prediction error estimation: a comparison of resampling methods. *Bioinformatics*, v. 21(15), p. 3301–3307.
- MORGAN, A. & MANNERING, F. (2011) The effects of road-surface conditions, age, and gender on driver-injury severities. *Accident Analysis and Prevention*, v. 43(5), p. 1852–1863.
- MORRIS, M. D. (1991) Factorial sampling plans for preliminary computational experiments. *Technometrics*, v. 33, p. 161–174.
- MUSA, I. J. & MOSES, A. O. (2014) An analysis of the effect of land use on road traffic accidents in Zaria. *International Journal of Development and Sustainability*, v. 3(3), p. 520-529.
- MUSSONE, L., FERRARI, A. & ONETA, M. (1999) An analysis of urban collisions using an artificial intelligence model. *Accident Analysis and Prevention*, v. 31(6), p. 705–718.
- NAGABUSHAN, N., SATISH, N. & RAGHURAM, S. (2016) Effect on injected noise in deep neural networks. *Proceedings of 2016 IEEE International Conference on Computational Intelligence and Computing Research*, Chennai, India.
- NAIR, V. & HINTON, G. E. (2010) Rectified Linear Units Improve Restricted Boltzmann Machines. *Proceedings of the 27th International Conference on Machine Learning*, Haifa, Israel, n. 3, p. 807–814.
- NANNI, L. & GHIDONI, S. (2017) How Could a Subcellular Image, or a Painting by Van Gogh, Be Similar to a Great White Shark or to a Pizza?. *Pattern Recognition Letters*, v. 85, p. 1–7.
- NANNI, L., GHIDONI, S. & BRAHNAM, S. (2017) Handcrafted vs. Non-Handcrafted Features for Computer Vision Classification. *Pattern Recognition*, v. 71, p. 158–172.
- NELDER, J. A. & WEDDERBURN, R. W. (1972) Generalized linear models. *Journal of the Royal Statistical Society*, v. 135(3), p. 370-384.
- NEUMANN, T. R., GLENNON, J. C. & SAAG, J. B. (1983) Accident analysis for highway curves. *Transportation Research Record*, n. 923, p. 54–57.
- NISBET, R., MINER, G. & YALE, K. (2018) *Handbook of Statistical Analysis and Data Mining Applications*. 2nd ed. Elsevier Inc., London, UK, 822 p.
- NODARI, C. T. (2016) *Minicurso Auditoria de Segurança Viária*. Material didático. 45ª Reunião Annual de Pavimentação/19º Encontro Nacional de Conservação Rodoviária, Brasília.
- NOGUEIRA, A. A. (1995) *Análise da relação da geometria de rodovias e acidentes envolvendo veículos de carga*. Dissertação de Mestrado em Transportes, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

- O'DONNELL, C. J. & CONNOR, D. H. (1996) Predicting the severity of motor-vehicle accident injuries using models of multiple ordered choice. *Accident Analysis and Prevention*, v. 28(6), p. 739-753.
- ODGEN, K. W. (1996) Safer roads: a guide to road safety engineering. Ashgate Publishing limited, University Press, Cambridge, UK, 516 p.
- OGLE, J., ALLURI, P. & SARASUA, W. (2011) MMUCC and MIRE: the role of segmentation in safety analysis. *Proceedings of the 90th Annual Meeting of the Transportation Research Board*, Washington, USA.
- OH, J., LYON, C., WASHINGTON, S., PERSAUD, B. & BARED, J. (2003) Validation of FHWA Crash Models for Rural Intersections: Lessons Learned. *Transportation Research Record*, n. 1840, p. 41-49.
- OÑA, J., LÓPEZ, G. & ABELLÁN, J. (2013a) Extracting decision rules from police accident reports through decision trees. *Accident Analysis and Prevention*, v. 50, p. 1151-1160.
- OÑA, J., LÓPEZ, G., MUJALLI, R. & CALVO, F. (2013b) Analysis of traffic accidents on rural highways using Latent Class Clustering and Bayesian Networks. *Accident Analysis and Prevention*, v. 51, p. 1-10.
- OÑA, J., MUJALLI, R. O. & CALVO, F. J. (2011) Analysis of traffic accident injury severity on Spanish rural highways using Bayesian networks. *Accident Analysis and Prevention*, v. 43, p. 402-411.
- OpenBUGS (2019) *OpenBUGS software*. Disponível em: <http://www.openbugs.net/>
- OQUAB, M., BOTTOU, L., LAPTEV, I. & SIVIC, J. (2014) Learning and Transferring Mid-Level Image Representations Using Convolutional Neural Networks. *Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, USA, p. 1717-1724.
- OTHMAN, S., THOMSON, R. & LANNER, G. (2009) Identifying critical road geometry parameters affecting crash rate and crash type. *Annals of Advances in Automotive Medicine*, v. 53, p. 155-165.
- PAN, S.J. & YANG, Q. (2010) A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, v. 22, p. 1345-1359.
- PARK, E. S. & LORD, D. (2007) Multivariate Poisson lognormal models for jointly modeling crash frequency by severity. *Transportation Research Record*, n. 2019, p. 1-6.
- PAULA, G. A. (2004) Modelos de regressão com apoio computacional. Universidade de São Paulo, São Paulo, Brasil, 441 p.
- PEDHAZUR, E. J. & SCHMELKIN, L. P. (1991) Measurement, Design, and Analysis: An Integrated Approach. Lawrence Erlbaum Associates, Hillsdale, USA, 819 p.
- PEDREGOSA, F., VAROQUAUX, G., GRAMFORT, A., MICHEL, V., THIRION, B., GRISEL, O., BLONDEL, M., PRETTENHOFER, P., WEISS, R., DUBOURG, V., VANDERPLAS, J., PASSOS, A., COURNAPEAU, D., BRUCHER, M., PERROT, M.



- & DUCHESNAY, E. (2011) Scikit-learn: machine learning in python. *Journal of Machine Learning Research*, v. 12, p. 2825-2830.
- PENG, X., ZHANG, G. Y. G. & SUN, J. (2017) *Large kernel matters improve semantic segmentation by global convolutional network*. arXiv:1703.02719 [cs.CV].
- PÉREZ, I. (2002) Experiencia norteamericana en modelos que relacionan el número de accidentes y las variables del proyecto geométrico de las carreteras convencionales. *Rutas Revista de la Asociación Técnica de Carreteras*, v. 88, p. 13-25.
- POWER, M. (1993) The predictive validation of ecological and environmental models. *Ecological Modelling*, v. 68, p. 33-50.
- PYTHON (2019) *Python Software Foundation*. Disponível em: <https://www.python.org/>
- QIN, X. & WELLNER, A. (2012) Segment Length Impact on Highway Safety Screening Analysis. *Proceedings of the 91st Annual Meeting of the Transportation Research Board*, Washington, USA.
- QU, X., YANG, Y., LIU, Z., JIN, S. & WENG, J. (2014) Potential crash risks of expressway on-ramps and off-ramps: A case study in Beijing, China. *Safety Science*, v. 70, p. 58-62.
- QUINLAN, J. R. (1986) Induction of Decision Trees. *Machine Learning*, v. 1, p. 81-106.
- R DEVELOPMENT CORE TEAM (2019) *R: A language and environment for statistical computing*, R Foundation for Statistical Computing. Vienna, Austria. Disponível em: <http://www.r-project.org/>.
- RATANAVARAHA, V. & SUANGKA, S. (2014) Impacts of accident severity factors and loss values of crashes on expressways in Thailand. *IATSS Research*, v. 37, p. 130-136.
- RESENDE, P. & BENEKOHAL, R. (1997) Effect of roadway section length on accident modelling traffic congestion and traffic safety. *Proceedings of 21st Century Conference*, Chicago, USA.
- RODRIGUES, C. A. S. P. (2018) *Implementação de redes convolucionais para a segmentação de imagens em tempo real com vistas a aplicação em robôs autônomos com dispositivos de visão de baixo custo*. Dissertação de Mestrado em Engenharia Elétrica e de Computação, Escola de Engenharia Elétrica, Mecânica e de Computação, Universidade Federal de Goiás, Goiânia.
- ROTHLAUF, F. (2011) *Design of Modern Heuristics: Principles and Application*. 1st ed. Springer Publishing Company Inc., New York, 280 p.
- ROYSTON, P. & SAUERBREI, W. (2008) *Multivariable model-building. A pragmatic approach to regression analysis based on fractional polynomials for modelling continuous variables*. John Wiley & Sons, Chichester, UK, 303 p.
- RUDER, S. (2016) *An overview of gradient descent optimization algorithms*. arXiv:1609.04747 [cs.LG].

- RUSSEL, S. & NORVIG, P. (2003) *Artificial Intelligence: A Modern Approach*. 2nd ed. Prentice Hall, Upper Saddle River, USA, 1132 p.
- SAHA, D., ALLURI, P. & GAN, A. (2015) Prioritizing Highway Safety Manual's crash prediction variables using boosted regression trees. *Accident Analysis and Prevention*, v. 79, p. 133-144.
- SAHA, D., ALLURI, P. & GAN, A. (2016) A random forests approach to prioritize Highway Safety Manual (HSM) variables for data collection. *Journal of Advanced Transportation*, v. 50, p. 522-540.
- SALTELLI, A. (2002) Making best use of model evaluations to compute sensitivity indices. *Computer Physics Communications*, v. 145, p. 280–297.
- SALTELLI, A., ANNONI, P., AZZINI, I., CAMPOLONGO, F., RATTO, M. & TARANTOLA, S. (2010) Variance based sensitivity analysis of model output - Design and estimator for the total sensitivity index. *Computer Physics Communications*, v. 181, p. 259–270.
- SALTELLI, A., TARANTOLA, S., CAMPOLONGO, F. & RATTO, M. (2004) *Sensitivity analysis in practice - A guide to assessing scientific models*. John Wiley and Sons, West Sussex, UK, 232 p.
- SAMEEN, M. I. & PRADHAN, B. (2017) Assessment of the effects of expressway geometric design features on the frequency of accident crash rates using high resolution laser scanning data and GIS. *Geomatics, Natural Hazards and Risk*, v. 8(2), p. 733-747.
- SANCHEZ-PINTO, L. N., VENABLE, L. R., FAHRENBACH, J. & CHURPEK, M. M. (2018) Comparison of variable selection methods for clinical predictive modeling. *International Journal of Medical Informatics*, v. 116, p. 10-17.
- SAVOLAINEN, P. T., MANNERING, F. L., LORD, D. & QUDDUS, M. A. (2011) The statistical analysis of highway crash-injury severities: A review and assessment of methodological alternatives. *Accident Analysis and Prevention*, v. 43, p. 1666-1676.
- SCHAUL, T., BAYER, J., WIERSTRA, D., SUN, Y., FELDER, M., SEHNKE, F., RUCKSTIEß, T. & SCHMIDHUBER, J. (2010) PyBrain. *The Journal of Machine Learning Research*, v. 11, p. 743–746.
- SCHOLKOPF, B. & SMOLA A. J. (2002) *Learning with Kernels*. MIT Press, Cambridge, UK, 626 p.
- SERMANET, P. & LECUN, Y. (2011) Traffic sign recognition with multi-scale convolutional networks. *Proceedings of 2011 International Joint Conference Neural Networks (IJCNN)*, San Jose, USA, p. 2809-2813.
- SETIONO, R. & LEOW, W. K. (2000) *A Pruned Neural Networks for Regression*. PRICAI 2000 Topics in Artificial Intelligence. Lecture Notes in Computer Science, Mizoguchi R., Slaney J. (eds), Springer, Berlin, P. 500-509.

- SETIONO, R. & THONG, J. Y. L. (2004) An Approach to Generate Rules from Neural Networks for Regression Problems. *European Journal of Operational Research*, v. 155(1), p. 239-250.
- SHANKAR, V., MANNERING, F. & BARFIELD, W. (1995) Effect of roadway geometrics and environmental factors on rural freeway accident frequencies. *Accident Analysis and Prevention*, v. 27(3), p. 371-389.
- SHAO, J. (1993) Linear model selection by cross validation. *Journal of American Statistical Association*, v. 88(422), p. 486–494.
- SHARMA, A. (2014) *Information Discovery from Constraints for Evolutionary Computational Model*. Tese de Doutorado, Faculty of Education, Science, Technology and Mathematics, University of Canberra, Canberra, Australia.
- SHUAI, Z., ZUO, B.W. B. & WANG, G. (2016) Dag-recurrent neural networks for scene labeling. *Proceedings of 2016 IEEE Computer Vision Foundation Conference*, Las Vegas, USA.
- SILVA, A. S. (2016) *Desenvolvimento de um método para avaliação do desempenho térmico e energético de edificações aplicando análise de incertezas e sensibilidade*. Tese de Doutorado em Engenharia Civil, Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis.
- SILVA, K. C. R. (2017) *Assessing the transferability of crash prediction models for two lane highways in Brazil*. Tese de Doutorado em Engenharia de Transportes, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.
- SIMONYAN, K. & ZISSERMAN, A. (2015) Very deep convolutional networks for large-scale image recognition. *Proceedings of the 3rd International Conference on Learning Representations*, San Diego, USA.
- SINAY, M. C. F. & TAMAYO, A. S. (2005) Segurança Viária: Uma Visão Sistêmica. *Anais do III Rio de Transportes*, Rio de Janeiro, Brasil.
- SOBOL', I. M. (1993) Sensitivity Estimates for Nonlinear Mathematical Models. *Mathematical Modeling & Computational Experiment*, v. 1(4), p. 407-414.
- SOBOL', I. M. (2001) Global sensitivity indices for nonlinear mathematical models and their Monte Carlo estimates. *Mathematics and Computers in Simulation*, v. 55, p. 271–280.
- SOHN, S. Y. & LEE, S. H. (2003) Data fusion, ensemble and clustering to improve the classification accuracy for the severity of road traffic accidents in Korea. *Safety Science*, v. 41, p. 1-14.
- SONG, J. J., GHOSH, M., MIAOU, S. & MALLICK, B. (2006) Bayesian multivariate spatial models for roadway traffic crash mapping. *Journal of Multivariate Analysis*, v. 97(1), p. 246–273.
- SONG, Y., LIANG, J., LU, J. & ZHAO, X. (2017) An efficient instance selection algorithm for k nearest neighbor regression. *Neurocomputing*, v. 251, p. 26-34.

- SOULEYRETTE, R. R., HAAS, R. P. & MAZE, T. H. (2007) Validation and implication of segmentation on Empirical Bayes for highway safety studies. *WIT Transactions on Biomedicine and Health*, v. 11, p. 85-94.
- STAMATIADIS, N., PIGMAN, J., SACKSTEDER, J., RUFF, W. & LORD, D. (2009) *Impact of shoulder width and median width on safety*. NCHRP Report 633, Transportation Research Board, Washington, USA.
- SUDHEER, K. P. (2005) Knowledge extraction from trained neural network river flow models. *Journal of Hydrologic Engineering*, v. 10, p. 264-269.
- TAN, P. N., STEINBACH, M. & KUMAR, V. (2005) Introduction to Data Mining. 1st ed. Addison-Wesley Longman Publishing Co., Boston, USA, 792 p.
- TAZHIBI, M., KAZEMI, I., MOMENYAN, S. & HAGHSHENAS, H. (2013) Multivariate poisson lognormal model for modeling related factors in crash frequency by severity. *International Journal of Environmental Health Engineering*, v. 2(2), p. 1-6.
- TIGHE, S., LI, N., FALLS, L. C. & HAAS, R. (2000) Incorporating road safety into pavement management. *Transportation Research Record*, n. 1699, p. 1-10.
- TRABELSI, A., ELOUEDI, Z. & LEFEVRE, E. (2019) Decision tree classifiers for evidential attribute values and class labels. *Fuzzy Sets and Systems*, v. 366, p. 46-62.
- VAN DER HORST, R. & DE RIDDER, S. (2007) Influence of Roadside Infrastructure on Driving Behavior: Driving Simulator Study. *Transportation Research Record*, n. 2018, p. 36-44.
- VIEIRA, V., RAZENTE, H. L. & BARIONI, M. C. N. (2017) Tópicos em Gerenciamento de Dados e Informações 2017. Sociedade Brasileira de Computação, Uberlândia, Brasil, 94 p.
- VILLIERS, J. & BARNARD, E. (1993) Back Backpropagation neural nets with one and two hidden layers. *IEEE Transactions on Neural Networks and Learning Systems*, v. 4(1), p. 136-141.
- WAIHRICH, D. R. L. S. (2016) *Calibração do método de previsão de acidentes do Highway Safety Manual (HSM) para trechos rodoviários de pista dupla no Brasil*. Dissertação de Mestrado em Transportes, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília.
- WANG, C., QUDDUS, M. A. & ISON, S. G. (2011) Predicting accident frequency at their severity levels and its application in site ranking using a two-stage mixed multivariate model. *Accident Analysis and Prevention*, v. 43(6), p. 1979-1990.
- WANG, K., IVAN, J. N., RAVISHANKER, N. & JACKSON, E. (2017) Multivariate Poisson lognormal modeling of crashes by type and severity on rural two lane highways. *Accident Analysis and Prevention*, v. 99, p. 6-19.
- WANG, K., ZHAO, S. & JACKSON, E. (2018) Multivariate Poisson Lognormal Modeling of Weather-Related Crashes on Freeways. *Transportation Research Record*, n. 2672, p. 184-198.

- WANVIK, P. O. (2009) Effects of Road Lighting on Motorways. *Traffic Injury Prevention*, v. 10(3), p. 279-289.
- WHO (2015) World Health Organization. *Global Status Report on Road Safety 2015*. Geneva, Switzerland. 323 p.
- WINKELMAN, R. (2003) *Econometric Analysis of Count Data*. 4th ed. Springer, New York, USA, 193 p.
- WONG, S. C., SZE, N. N. & LI, Y. C. (2007) Contributory factors to traffic crashes at signalized intersections in Hong Kong. *Accident Analysis and Prevention*, v. 39, p. 1107-1113.
- WRI (2018) World Resources Institute. *Sustainable & Safe: A Vision and Guidance for Zero Road Deaths*. Washington, USA. 76 p.
- XIE, Y., LORD, D. & ZHANG, Y., (2007) Predicting motor vehicle collisions using Bayesian neural networks: An empirical analysis. *Accident Analysis and Prevention*, v. 39(5), p. 922-933.
- YE, X., PENDYALA, R., SHANKAR, V. & KONDURI, K. (2013) A simultaneous equations model of crash frequency by severity level for freeway sections. *Accident Analysis and Prevention*, v. 57, p. 140–149.
- YOSINSKI, J., CLUNE, J., BENGIO, Y. & LIPSON, H. (2014) How Transferable Are Features in Deep Neural Networks?. *Proceedings of the 27th International Conference on Neural Information Processing Systems*, Montreal, Canada, p. 3320–3328.
- YU, H., XIE, T. & WILAMOWSKI, B. M. (2011) Advantages of Radial Basis Function Networks for Dynamic System Design. *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS*, v. 58(12), p. 5438-5450.
- YU, X. & GEN, M. (2010) *Introduction to evolutionary algorithms*. Springer, London, UK, 436 p.
- ZEGEER, C. V., TWOMEY, J. M., HECKMAN, M. L. & HAYWARD, J. C. (1992) *Safety effectiveness of highway design features: Volume II, Alignment*. Report FHWA-RD-91-045, Federal Highway Administration, Washington, USA.
- ZENG, Q. & HUANG, H. (2014) A stable and optimized neural network model for crash injury severity prediction. *Accident Analysis and Prevention*, v. 73, p. 351–358.
- ZENG, Q., HUANG, H., PEI, X. & WONG, S. C. (2016b) Modeling nonlinear relationship between crash frequency by severity and contributing factors by neural networks. *Analytic Methods in Accident Research*, v. 10, p. 12–25.
- ZENG, Q., HUANG, H., PEI, X., WONG, S. C. & GAO, M. (2016a) Rule extraction from an optimized neural network for traffic crash frequency modeling. *Accident Analysis and Prevention*, v. 97, p. 87–95.

- ZHAN, X., AZIZ, H. M. A. & UKKUSURI, S. V. (2015) An efficient parallel sampling technique for Multivariate Poisson Lognormal model: analysis with two crash count datasets. *Analytic Methods in Accident Research*, v. 8, p. 45–60.
- ZHANG, C. & IVAN, J. (2005) Effects of geometric characteristics on head-on crash incidence on two-lane roads in Connecticut. *Transportation Research Record*, n. 1908, p. 159-164.
- ZHANG, P. (1993) Model selection via multi fold cross validation. *The Annals of Statistics*, v. 21(1), p. 299–313.
- ZHANG, X-Y, TRAME, M. N., LESKO, L. J. & SCHMIDT, S. (2015) Sobol Sensitivity Analysis: A Tool to Guide the Development and Evaluation of Systems Pharmacology Models. *CPT Pharmacometrics & Systems Pharmacology*, v. 4, p. 69–79.
- ZHAO, M., LIU, C., LI, W. & SHARMA, A. (2018) Multivariate Poisson lognormal model for analysis of crashes on urban signalized intersections approach. *Journal of Transportation Safety & Security*, v. 10(3), p. 251-265.
- ZHENG, L., ZHAO, Y., WANG, S., WANG, J. & Q. TIAN (2016) *Good practice in CNN feature transfer*. arXiv:1604.00133 [cs.CV].
- ZUR, R. M., JIANG, Y. & METZ, C. E. (2004) Comparison of two methods of adding jitter to artificial neural network training. *Proceedings of International Congress Series*, Chicago, USA, p. 886–889.
- ZUR, R. M., JIANG, Y., PESCE, L. L. & DRUKKER, K. (2009) Noise injection for training artificial neural networks: A comparison with weight decay and early stopping. *Medical Physics*, v. 36(10), p. 4810-4818.

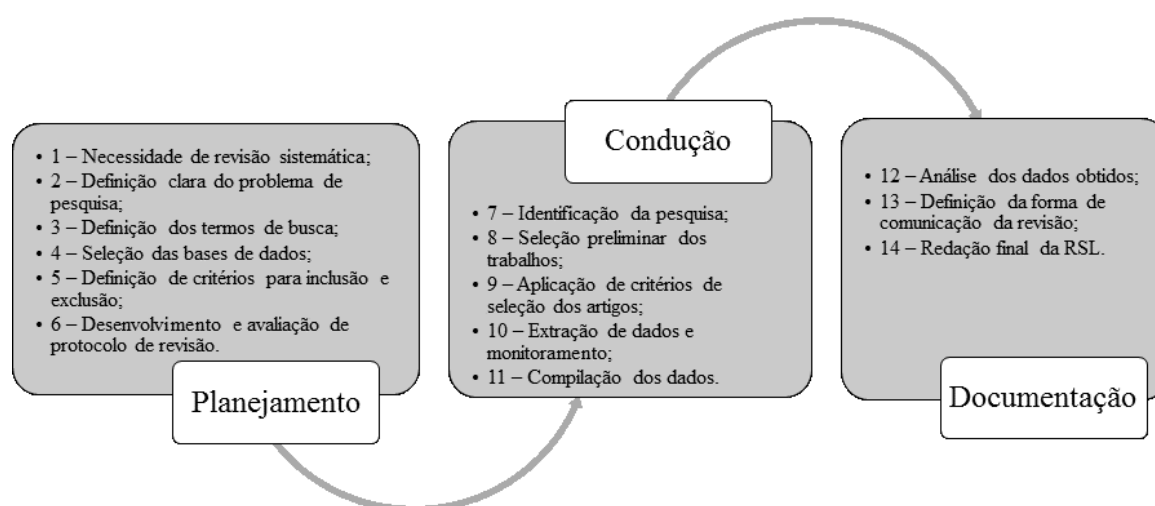
## **APÊNDICE A – REVISÃO SISTEMÁTICA DA LITERATURA**

## A.1. INTRODUÇÃO

A Revisão Sistemática da Literatura (RSL) objetiva a identificação de estudos sobre um tema específico, permitindo a canalização dos esforços para bibliografias de qualidade e de real interesse para a pesquisa.

O início da RSL é remetido à área da Medicina, no entanto, devido ao seu rigor metodológico e caráter inovador, diversas áreas do conhecimento têm incorporado suas diretrizes ao proceder à revisão de literatura.

Neste trabalho utilizou-se o procedimento proposto por Kitchenham (2007), consistindo em três fases: planejamento, condução e documentação da revisão. Na Figura A.1 está apresentado o esquema geral da RSL.



**Figura A.1-** Esquema geral do procedimento de revisão

## A.2. PLANEJAMENTO

Mesmo sendo uma temática relevante e atual, não foi identificada publicação que abordasse de forma abrangente o estado da arte sobre modelagem da segurança viária por meio de técnicas de aprendizado de máquina, sendo a temática tratada como um tópico superficial em publicação sobre modelagem estatística da segurança viária.

A temática da revisão foi: modelos de previsão de frequência e gravidade de acidentes de trânsito, com recurso a técnica de aprendizado de máquina. A partir da temática, objetivo do trabalho e RSL anterior, foi possível definir os termos de busca.



Os termos de busca foram divididos em dois grupos: o primeiro relativo a modelos de previsão de acidente e, o segundo às técnicas de aprendizado de máquina. As *strings* foram definidas de forma a considerar a ocorrência de um termo de modelos de previsão de acidentes associado a um termo relativo a aprendizado de máquina.

As plataformas selecionadas para a execução da pesquisa foram: Portal de Periódicos CAPES e Google Acadêmico. O Portal de Periódicos CAPES foi eleito por abarcar diversas bases de dados consolidadas, a saber: *Web of Science*, *Scopus*, *Journal Citation Reports*, *Engineering Village*, *MAS*, *ASTM International*, *SciFinder*, *ProQuest*, *Britannica Academic Edition*, *Thomson Reuters*, *Eighteenth Century Collections Online*, *Begell House*. Doutro lado, o Google Acadêmico é uma plataforma mais abrangente, capturando resultados não alcançados pelas outras bases de dados.

### A.3. CONDUÇÃO

Após definição do protocolo de execução da revisão, procedeu-se à condução da mesma. Na Tabela A.1 está sintetizada a execução do protocolo.

**Tabela A.1 - Condução da RSL**

Definição do problema de pesquisa
<ul style="list-style-type: none"> <li><b>Problema de pesquisa</b> Como modelar previsão de acidentes (frequência e severidade) em rodovias, com uso de aprendizado de máquina?</li> </ul>
Definição das estratégias de pesquisa
<b>Horizonte de tempo:</b> 1975 a 2017
<b>Bases de pesquisas:</b> Portal de Periódicos CAPES ( <i>Web of Science</i> , <i>Scopus</i> , <i>Journal Citation Reports</i> , <i>Engineering Village</i> , <i>MAS</i> , <i>ASTM International</i> , <i>SciFinder</i> , <i>ProQuest</i> , <i>Britannica Academic Edition</i> , <i>Thomson Reuters</i> , <i>Eighteenth Century Collections Online</i> , <i>Begell House</i> ) e Google Acadêmico.
<b>Grupo 1:</b> publicações relacionadas a previsão de acidentes e aprendizado de máquina. Termos de busca 1. (“ <i>Accident prediction</i> ” OR “ <i>Crash accident</i> ” OR “ <i>Injury severity</i> ” OR “ <i>Accident model*</i> ” OR “ <i>Road traffic accident</i> ” OR “ <i>Motor vehicle collision*</i> ” OR “ <i>Crash injury accident*</i> ” OR “ <i>Crash frequenc*</i> ” OR <i>Crash frequenc* by severity</i> OR “ <i>Crash prediction</i> ”) AND “ <i>Artificial intelligence</i> ”; 2. (“ <i>Accident prediction</i> ” OR “ <i>Crash accident</i> ” OR “ <i>Injury severity</i> ” OR “ <i>Accident model*</i> ” OR “ <i>Road traffic accident</i> ” OR “ <i>Motor vehicle collision*</i> ” OR “ <i>Crash injury accident*</i> ” OR “ <i>Crash frequenc*</i> ” OR <i>Crash frequenc* by severity</i> OR “ <i>Crash prediction</i> ”) AND “ <i>Expert system*</i> ”; 3. (“ <i>Accident prediction</i> ” OR “ <i>Crash accident</i> ” OR “ <i>Injury severity</i> ” OR “ <i>Accident model*</i> ” OR “ <i>Road traffic accident</i> ” OR “ <i>Motor vehicle collision*</i> ” OR “ <i>Crash injury accident*</i> ” OR “ <i>Crash frequenc*</i> ” OR <i>Crash frequenc* by severity</i> OR “ <i>Crash prediction</i> ”) AND “ <i>Machine learning</i> ”

---

**Grupo 2:** publicações relacionadas a previsão de acidentes e redes neurais artificiais. Termos de busca 1. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND “Artificial neural network”; 2. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND “Neural network”; 3. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND “ANN”.

---

**Grupo 3:** publicações relacionadas a previsão de acidentes e lógica fuzzy. Termos de busca 1. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND Bayesian network.

---

**Grupo 4:** publicações relacionadas a previsão de acidentes e lógica fuzzy. Termos de busca 1. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND Fuzzy logic.

---

**Grupo 5:** publicações relacionadas a previsão de acidentes e programação genética. Termos de busca 1. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND Genetic programming; 2. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND Genetic algorithm.

---

**Grupo 6:** publicações relacionadas a previsão de acidentes e árvores de decisão. Termos de busca 1. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND decision Tree; 2. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND (Classification and regression tree OR “CART”).

---

**Grupo 7:** publicações relacionadas a previsão de acidentes e raciocínio baseado em casos. Termos de busca 1. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND (Case based reasoning OR CBR).

---

**Grupo 8:** publicações relacionadas a previsão de acidentes e raciocínio baseado em casos. Termos de busca 1. (“Accident prediction” OR “Crash accident” OR “Injury severity” OR “Accident model\*” OR “Road traffic accident” OR “Motor vehicle collision\*” OR “Crash injury accident\*” OR “Crash frequenc\*” OR Crash frequenc\* by severity OR “Crash prediction”) AND (Support Vector Machine OR “SVM”).

---

#### Definição de critérios para inclusão ou exclusão de trabalhos

- Critérios de exclusão

- Todos os trabalhos sem disponibilidade de acesso;
- Todos os trabalhos que não sejam artigos científicos;
- Todos os resultados repetidos;
- Todos os trabalhos especializados que não se enquadrem no escopo de Transportes;
- Todos os trabalhos que não estejam em inglês, português ou espanhol.

- Critérios de inclusão

- Todos os trabalhos que atendam aos grupos 1 a 8, inclusive por meio de *snowball sampling*.

---

#### Seleção de trabalhos

---

<ul style="list-style-type: none"> <li>• Critério de seleção</li> <li>- Trabalhos que tratem de modelos de previsão de acidentes com uso de técnicas de aprendizado de máquina, especialmente em rodovias;</li> <li>- Trabalhos com Fator de impacto JCR ou índice SJR superior a 0,50.</li> </ul>
<b>Análise dos trabalhos selecionados</b>
<ul style="list-style-type: none"> <li>• Elementos para análise</li> <li>- Objetivo do modelo de previsão de acidentes;</li> <li>- Técnica(s) de aprendizado de máquina empregada(s);</li> <li>- Cenário da modelagem (tipo de rodovia, país, variáveis utilizadas).</li> </ul>
<b>Apresentação dos resultados</b>
<ul style="list-style-type: none"> <li>• Resultado</li> <li>- Elaboração da revisão bibliográfica da tese.</li> </ul>

### A.3.1. Trabalhos Identificados

Na Tabela A.2 está apresentada a relação dos trabalhos identificados após a execução das estratégias de pesquisa, perfazendo o total de 341782 resultados. Ainda na Tabela A.2, os números entre parênteses no TOTAL representam os trabalhos restantes com título ou resumo aderente após a aplicação inicial dos filtros.

**Tabela A.2 - Relação de estudos identificados**

Termos de busca	Plataformas de busca		TOTAL	
	Periódicos CAPES	Google Acadêmico		
<b>Grupo 1</b>	1.	9713	3620	13333
	2.	52431	1948	54379
	3.	17504	3010	20514
<b>Grupo 2</b>	1.	4565	2095	6660
	2.	17745	6510	24255
	3.	10219	32800	43019
<b>Grupo 3</b>	1.	3966	7650	11616
<b>Grupo 4</b>	1.	3517	4380	7897
<b>Grupo 5</b>	1.	3789	9660	13449
	2.	9222	9010	18232
<b>Grupo 6</b>	1.	19978	27960	47938
	2.	12098	14100	26198
<b>Grupo 7</b>	1.	26160	17070	43230
<b>Grupo 8</b>	1.	5012	6050	11062
<b>TOTAL</b>		195919 (118)	145863 (195)	341782 (313)

As *strings* foram definidas mediante exploração prévia de trabalhos e termos de busca, para terem capacidade de capturar todos os trabalhos úteis e diretamente relacionados ao objetivo da tese, mesmo diante de diferentes nomenclaturas e termos. Entretanto, o alto número de trabalhos identificados indica as *strings* não foram eficientemente processadas pelos motores de busca das plataformas consultadas.

Ainda assim, os resultados da RSL não foram comprometidos, já que a busca tornou-se mais abrangente, em contrapartida, o processo de identificação e escolha dos trabalhos foi mais árduo e moroso. Frente a este desafio, teve-se como estratégia o ordenamento dos trabalhos por “Relevância” e verificação destes até se observar a não ocorrência dos descritores de busca no título ou resumo.

É oportuno, portanto, entender como é feita a ordenação por “Relevância”. Este *ranking* tem como principais características i) Periódicos Capes: atribuição de pesos diferentes à existência do termo de busca em locais diferentes, bem como a quantidade de vezes que os termos aparecem, consideração da ordem dos termos de busca e a sua proximidade tanto nos metadados quanto no texto completo (“*search-wise distance*”), consideração de medidas de utilização do texto da citação por usuários do Primo em todo o mundo e datas de publicação (CAPES, 2017); ii) Google Acadêmico: consideração do texto integral do artigo, do autor, frequência e local de citações do artigo (GOOGLE SCHOLAR, 2017).

### **A.3.2. Trabalhos Selecionados**

Procedeu-se ao refinamento dos 313 artigos inicialmente selecionados, por meio da aplicação dos demais critérios de exclusão e inclusão. Como critério de inclusão nesta etapa fez-se a análise “bola de neve” (*snowball sampling*). De posse dos artigos retornados pela RSL, a lista de referências bibliográficas de cada um foi analisada, sendo selecionados artigos com conteúdo aderente ao tema e que não constavam no conjunto de artigos já selecionados, ocorrendo o encerramento do processo quando a saturação teórica foi alcançada, situação em que novas referências não adicionam mais informação relevante ao fator estudado. Este procedimento gerou a inclusão de 4 artigos aos 313 trabalhos iniciais, totalizando 317 artigos.

Deste novo total foram excluídos os trabalhos sem disponibilidade de acesso, os que não eram artigos científicos, os resultados repetidos, os trabalhos fora do escopo de Transportes e aqueles em língua diferente de inglês, português ou espanhol. Após aplicação destes critérios de exclusão, ainda restaram 97 artigos.

Quanto à seleção dos artigos, com vistas a basear a revisão em artigos de maior qualidade, foram selecionados apenas artigos de periódicos com Fator de impacto JCR (*Thomson Scientific's Journal Citation Reports*) ou índice SJR (*SCImago Journal Rank*) superior a 0,50.

Em seguida, com os artigos resultantes do procedimento anterior, fez-se a análise detalhada dos trabalhos e verificação do enquadramento ao propósito da RSL, tendo sido excluídos os irrelevantes. Assim, finalmente, foram escolhidos 21 artigos.

Na Tabela A.3 estão apresentados os detalhes de publicação destes trabalhos. Quanto aos periódicos, é perceptível que o *Accident Analysis and Prevention* tem a maior expressividade dentro do tema, até porque trata-se de uma revista vocacionada para acidentes, em especial de trânsito. Seguindo a ordem, a segunda revista mais expressiva é a *Safety Science*, tendo quase 30% dos artigos analisados. Destaca-se, outrossim, que estes dois periódicos possuem o maior fator de impacto dentre os periódicos elencados. As demais revistas possuem a mesma representatividade em termos percentuais, com apenas um artigo cada uma.

**Tabela A.3 - Relação de artigos publicados em periódicos, por ano**


Periódico	Número de artigos/ano	SUBTOTAL	%
<i>Accident Analysis and Prevention</i>	(2/2006) (1/2007) (1/2008) (1/2010) (1/2011) (2/2013) (1/2014) (1/2015) (2/2016)	12	57,14
<i>Analytic Methods in Accident Research</i>	(1/2016)	1	4,76
<i>Journal of Safety Research</i>	(1/2005)	1	4,76
<i>Journal of Transportation Engineering</i>	(1/2004)	1	4,76
<i>Promet - Traffic &amp; Transportation</i>	(1/2015)	1	4,76
<i>Safety Science</i>	(1/2003) (1/2005) (2/2011) (1/2013)	5	23,82
<b>TOTAL DE ARTIGOS EM PERIÓDICOS</b>		21	

Na Figura A.2 foram agrupadas as publicações por período temporal e continente. Complementarmente, na Tabela A.4 é apresentada a relação dos artigos publicados por país e ano. Verificou-se que as publicações estão concentradas em apenas sete países. Os Estados Unidos lideram o *ranking* geral de publicações, com um terço dos artigos selecionados. Essa proporção aumenta quando se considera a origem dos dados utilizados na modelagem, saltando para quase 43%, uma vez que pesquisadores chineses e coreanos desenvolveram modelos a partir de dados americanos. E ainda, no continente americano somente os Estados Unidos possuem publicações.

Na sequência, com mesmo percentual, são países com representatividade nas publicações: China e Espanha. Os demais países não apresentam expressividade destacada, tendo apenas um ou dois artigos.

Em se tratando de termos continentais, a Ásia possui o maior número de publicações, atingido maior número de publicações no período de 2015 a 2016. Estes trabalhos estão distribuídos entre em cinco países, a saber: China, Coreia do Sul, Irã, Taiwan e Turquia.

No continente europeu apenas a Espanha figurou no rol de países com publicações selecionadas, ao passo que África e Oceania não possuem nenhum trabalho dentre os artigos selecionados.



**Figura A.2-** Relação temporal e continental de publicações em periódicos

**Tabela A.4-** Relação de número de trabalhos publicados por país (primeiro autor)/por ano

País	Número de artigos/ano	TOTAL	%
<i>China</i>	(1/2014) (1/2016)	3	14,29
<i>Coreia do Sul</i>	(1/2003) (1/2015)	2	9,52
<i>Espanha</i>	(1/2011) (2/2013)	3	14,29
<i>Estados Unidos da América</i>	(1/2004) (1/2006) (1/2007) (1/2008) (1/2010) (1/2011) (1/2016)	7	33,33
<i>Irã</i>	(1/2011) (1/2013)	2	9,52
<i>Taiwan</i>	(2/2005) (1/2006)	3	14,29
<i>Turquia</i>	(1/2015)	1	4,76
<b>TOTAL</b>		<b>21</b>	


Em termos temporais, observa-se que na América há uma distribuição quase uniforme, à exceção do período de 2013 a 2014 que não possui publicações. Na Ásia não é identificada uniformidade no número de publicações ao longo do tempo e ainda, nota-se uma lacuna de

publicação entre 2007 e 2010. Douro lado, a Espanha apresenta as publicações concentradas apenas entre 2011 e 2013.

Do mesmo modo, constatou-se que as publicações americanas, à exceção de dois trabalhos, são oriundas de duas universidades em que pelo menos um dos autores está presente em todos os artigos publicados pelo respectivo grupo de pesquisa. Analogamente, verificou-se que todos os artigos espanhóis têm o primeiro autor em comum, caracterizando uma sequência de estudos realizados por aquele grupo de pesquisa. O fato se repete na China, onde dois autores estão presentes em todas as publicações selecionadas daquele país. Mesma situação ocorre em Taiwan, onde o primeiro autor está presente em todos os artigos. Contrariamente, nos demais países (Coreia do Sul, Irã e Turquia) não existe autoria comum entre os artigos.

Cumprе salientar a inexistência de artigos brasileiros com a abordagem proposta nesta tese, o que reforça a importância do desenvolvimento deste trabalho visando inserir o Brasil no rol de países que investigam essa questão.

Numa análise complementar, na Figura A.3 são apresentados os valores acumulados de publicações em periódicos por continente. Nota-se a tendência crescente de estudos nesta área na Ásia, especialmente nos últimos anos. Na América, ao que parece, identifica-se um padrão de crescimento–estabilização–crescimento de publicações, tendo saído em 2016 da estagnação. Desta forma, em análise geral, os dados indicam potencial para investigação nesta área.



**Figura A.3** - Relação temporal e continental de valores acumulados de publicações em periódicos


#### A.4. DOCUMENTAÇÃO

A última etapa da RSL é a documentação, momento em que os artigos são sistematizados e analisados, extraindo-se informações úteis para o desenvolvimento da tese.

Após a execução de todos os procedimentos busca e escolha de trabalhos foram selecionados 21 artigos, os quais contemplam modelos de previsão de acidentes desenvolvidos com técnicas de AM e que tenham um dos seguintes propósitos de previsão/classificação: frequência, severidade ou frequência e severidade.

Os trabalhos selecionados foram analisados e suas informações organizadas e sistematizadas, de modo a se permitir a ponderação quanto aos tipos de modelagens, objeto de estudo, dados de entrada, dados de saída, medidas de desempenho dos modelos, dentre outras características. Essa sistematização proporciona uma visão profunda e crítica do tem sido investigado neste assunto.

Na Tabela A.5 apresenta-se, em ordem cronológica, a relação das publicações, destacando-se o país do primeiro autor, o tipo de modelagem e as técnicas utilizadas. Na Figura A.4 é demonstrada a proporção de cada tipo de modelagem identificada, sendo notória a predominância de modelos de previsão de acidentes por severidade ou gravidade de lesão de ocupantes. Seguidamente estão os modelos de previsão de frequência de acidentes, correspondendo a cerca de 30% dos modelos. Em contraste, foram identificados apenas dois modelos que abordam frequência e severidade de acidentes, sendo que apenas um deles faz a modelagem conjunta dos dois propósitos.



**Figura A.4** - Proporção dos tipos de modelagens identificadas



**Tabela A. 5** - Tipo de modelagem e técnicas utilizadas nos artigos selecionados

Referência	País	Tipo de modelagem	Técnica(s) utilizada(s)
Sohn e Lee (2003)	Coreia do Sul	Severidade	RNA; AD; AFC
Abdel-Aty e Abdelwahab (2004)	EUA	Severidade	RNA; ARTMAP; <u>MP</u>
Chang (2005)	Taiwan	Frequência	RNA; <u>NB</u>
Chang e Chen (2005)	Taiwan	Frequência	CART; <u>NB</u>
Delen <i>et al.</i> (2006)	EUA	Severidade	RNA
Chang e Wang (2006)	Taiwan	Severidade	CART
Xie <i>et al.</i> (2007)	EUA	Frequência	NB; RNA; RNB
Li <i>et al.</i> (2008)	EUA	Frequência	NB; SVM
Das e Abdel-Aty (2010)	EUA	Severidade	PG
Oña <i>et al.</i> (2011)	Espanha	Severidade	RB
Kashani e Mohaymany (2011)	Irã	Severidade	CART
Das e Abdel-Aty (2011)	EUA	Frequência e severidade de acidentes	PG
Oña <i>et al.</i> (2013a)	Espanha	Severidade	CART; AD
Oña <i>et al.</i> (2013b)	Espanha	Severidade	LCA; RB
Alikhani <i>et al.</i> (2013)	Irã	Severidade	RNA; ANFIS; AK; SOM
Zeng e Huang (2014)	China	Severidade	RNA; <u>ML</u>
Kwon <i>et al.</i> (2015)	Coreia do Sul	Severidade	CNB; AD; <u>ML</u>
Çodur e Tortum (2015)	Turquia	Frequência	RNA
Chen <i>et al.</i> (2016)	EUA	Severidade	CART; SVM
Zeng <i>et al.</i> (2016a)	China	Frequência	RNA
Zeng <i>et al.</i> (2016b)	China	Frequência por severidade	RNA; <u>MMP</u>
LEGENDA			
Técnicas de aprendizado de máquina			
AD: Árvores de decisão AFC: Algoritmos de fusão e conjuntos AK: Algoritmos k-means ANFIS: Sistema <i>neuro-fuzzy</i> ARTMAP: Redes neurais com teoria da ressonância adaptativa <i>fuzzy</i>	CART: Árvores de classificação e regressão CNB: Classificadores Naive Bayes LCA: Análise de classes latentes PG: Programação genética	RB: Redes Bayesianas RNA: Redes neurais artificiais RNB: Redes neurais Bayesianas SOM: <i>Self-Organizing Maps</i> SVM: Máquina de vetores de suporte	
Técnicas estatísticas			
ML: Modelo logit MP: Modelo probit	MMP: Modelo multivariado Poisson lognormal	NB: Modelo de regressão com distribuição binomial negativa	

Refere-se ainda, que foram identificados outros trabalhos cuja modelagem de acidentes também utilizava técnicas de AM, mas com propósitos diversos, tendo como variáveis dependentes, por exemplo: grau de responsabilidade do condutor na ocorrência do acidente, tipo de colisão, número de veículos ou pedestres envolvidos, etc. Ou ainda, modelos previsão ou severidade de

acidentes cujas variáveis de entrada utilizadas eram dados demográficos e socioeconômicos. Como estas abordagens estão fora do escopo do trabalho, não foram consideradas.

A seguir, na Figura A.5 é apresentada a distribuição dos trabalhos por tipo de técnica e na Figura A.6 são apresentados os valores acumulados de publicações por tipo de técnica. Estas representações são úteis na avaliação do potencial de utilização das técnicas e a trajetória de emprego ao longo dos anos.

Verifica-se a predominância do uso de redes neurais artificiais no desenvolvimento dos modelos de previsão de acidentes, o que torna-se mais intenso se enquadrarmos as Redes Neurais Bayesianas (RNB) na categoria RNA, correspondendo a 40% de utilização nos artigos analisados.

A outra abordagem que tem destaque são as árvores de classificação e regressão (CART), tipo particular das tradicionais árvores de decisão (AD), com representatividade de 17%. Tecnicamente, CART também são árvores de decisão, no entanto, os algoritmos de indução mais comuns são ID3 e C4.5 entendendo-se, em geral, AD como as que utilizam estes algoritmos. Ademais, o algoritmo CART tem ação diferente dos outros dois algoritmos, uma vez que é uma técnica não-paramétrica que induz tanto a árvores de classificação quanto árvores de regressão, a depender se o atributo é nominal (classificação) ou contínuo (regressão).

Admitindo-se ser a mesma técnica e procedendo-se ao agrupamento das publicações de CART e AD, este grupo representará um quarto de utilização entre os artigos selecionados. Modelos baseados em Programação Genética ou Máquina de Vetores de Suporte figuraram apenas em duas publicações cada um. As demais técnicas não se mostraram expressivas, já que cada uma foi utilizada em apenas uma investigação e algumas delas, apenas no tratamento preliminar dos dados ou de forma complementar a uma técnica mais robusta.




Figura A. 5- Tipos de técnicas empregadas.




Figura A. 6- Proporção dos tipos de modelagens identificadas

Da mesma forma foi possível verificar que as RNA tiveram padrão de crescimento de publicações entre os anos 2003 e 2007, seguida de uma estagnação no período de 2008 a 2012 e nova ascendência a partir de 2013. Nota-se ainda incremento ao coeficiente angular da reta de crescimento no ano de 2016. Tal curva de tendência dá indícios que a técnica tem potencial para ser explorada na modelagem da segurança viária.

Outra técnica que se destaca é a CART que, ao que parece, tem um padrão de crescimento-estabilização-crescimento em suaves patamares. Em 2016, a publicação de um artigo de modelo de previsão de acidentes utilizando-se desta técnica encerrou a inércia no crescimento de publicações.

AD e RNB são as outras duas técnicas que parecem ter ainda algum comportamento relevante, entretanto, ambas não possuem publicação no ano de 2016 e permanecem estagnadas,

especialmente RNB com a última publicação em 2013. As demais técnicas não demonstraram comportamento típico ou expressividade para análise.

#### **A.4.1. Redes Neurais Artificiais e Redes Bayesianas**

Como redes *perceptron* com camada única são capazes de resolver apenas problemas linearmente separáveis, todos os estudos desenvolvidos com RNA utilizaram redes *perceptron* multicamadas (*multilayer perceptron* – MLP), mesmo que não tenha sido explicitamente referido, como no caso de Sohn e Lee (2003).

O algoritmo de retropropagação de erro (*backpropagation algorithm*) é o mais utilizado no treinamento de redes neurais multicamadas. Basicamente, este treinamento consiste de dois passos, um passo para frente e um passo para trás (processamento direto e processamento reverso), respectivamente a propagação da entrada da rede às camadas posteriores e a retropropagação do erro que ocorre em sentido contrário da camada de saída às camadas ocultas. Neste processo é realizado o ajuste nos pesos sinápticos, a fim de minimizar o erro entre a saída produzida pela rede em relação a respectiva saída desejada (HAYKIN, 2001; HAYKIN, 2009).

Chang (2005), Delen *et al.* (2006), Xie *et al.* (2007), Alikhani *et al.* (2013), Çodur e Tortum (2015) utilizaram o algoritmo *backpropagation* no treinamento das redes desenvolvidas. Zeng e Huang (2014) desenvolveram redes neurais treinadas com o algoritmo *backpropagation* e também treinadas com algoritmo de Combinação Convexa (CC), constatando-se, por meio da comparação dos resultados, a superioridade deste último algoritmo. Por sua vez, Zeng *et al.* (2016a) e Zeng *et al.* (2016b) utilizaram o algoritmo de Gradientes Conjugados (CG) para o treinamento das redes. Já Sohn e Lee (2003) e Abdel-Aty e Abdelwahab (2004) não explicitaram qual o algoritmo de treinamento utilizado, no entanto, por essa omissão supõe-se que tenham utilizado o algoritmo *backpropagation*, o mais comum.

Em termos de função de ativação, comumente são utilizadas função logística ou hiperbólica. Delen *et al.* (2006), Alikhani *et al.* (2013) e Çodur e Tortum (2015) utilizar a função sigmoide logística, enquanto que Xie *et al.* (2007), Zeng *et al.* (2016a) e Zeng *et al.* (2016b) recorreram à função tangente hiperbólica. Zeng e Huang (2014) utilizaram nas redes treinadas com *backpropagation* função de ativação sigmoide e nas redes treinadas com algoritmo de

combinação convexa, a função tangente hiperbólica. Os demais autores não explicitaram a função de ativação utilizada.

Zeng e Huang (2014), Zeng *et al.* (2016a) e Zeng *et al.* (2016b) empregaram o algoritmo N2PFA (*NN pruning for function approximation*), proposto por Setiono e Leow (2000), para otimização da estrutura da rede neural. Segundo os autores, o algoritmo identifica os fatores insignificantes, realiza a poda destes e por consequência, reduz o tempo de processamento computacional e melhora a capacidade de generalização do modelo.

Embora seja viável utilizar duas ou mais camadas ocultas na estrutura da RNA, Villiers e Barnard (1993) constatou que o uso de camada oculta única conduz a resultados similares aos de redes com duas ou mais camadas ocultas, no entanto, com apenas uma camada reduz-se a probabilidade do treinamento da rede recair no mínimo local. Todos os trabalhos utilizaram apenas uma camada oculta na estrutura da rede, à exceção do Sohn e Lee (2003) que não fizeram referência a este parâmetro. Quanto aos neurônios na camada oculta, na Tabela A.6 estão apresentadas as diferentes quantidades empregadas pelos autores.

**Tabela A.6** - Tipo de modelagem e técnicas utilizadas nos artigos selecionados

Referência	Número de neurônios na camada oculta
Abdel-Aty e Abdelwahab (2004)	15
Chang (2005)	10
Delen <i>et al.</i> (2006)	18
Xie <i>et al.</i> (2007)	8
Alikhani <i>et al.</i> (2013)	12
Zeng e Huang (2014)	30 (rede treinada); 4 (rede otimizada)
Çodur e Tortum (2015)	9
Zeng <i>et al.</i> (2016a)	10 (rede treinada); 2-5 (rede otimizada)
Zeng <i>et al.</i> (2016b)	10 (rede treinada); 3, 4 e 6 (rede otimizada)

As RNA são bastante criticadas por serem tidas como “caixas-preta”, no entanto, em resposta a esta limitação os pesquisadores desenvolveram métodos para interpretar os resultados dos modelos. A análise de sensibilidade é um destes métodos, capaz de delinear o relacionamento entre os *inputs* e *outputs* de uma rede treinada. Tornou-se um método comumente utilizado para identificar a influência de cada variável independente sobre as variáveis dependentes (variáveis de saída). Durante o processo de análise de sensibilidade, o aprendizado da rede neural é desativado para que os pesos da rede não sejam afetados. Em termos gerais, o processo consiste em perturbar as variáveis de entrada e relatar a correspondente mudança como desvio percentual na saída. A primeira entrada é variada entre a sua média (mediana para as variáveis

categóricas) mais (ou menos) um desvio-padrão definido pelo usuário (limites de valores superior e inferior para as variáveis categóricas), enquanto todas as outras entradas são fixadas em suas respectivas médias (ou medianas). A saída da rede é calculada e registrada como a variação percentual absoluta acima e abaixo da média dessa variável de saída. Este processo é repetido para cada variável de entrada. Como resultado desse processo, é gerado um relatório (normalmente um gráfico de coluna ou uma tabela) que resume a variação de cada saída em relação à variação em cada entrada (FISH & BLODGETT, 2003; DELEN *et. al.*, 2006).

Delen *et al.* (2006), Zeng e Huang (2014), Chang (2005) e Çodur e Tortum (2015) utilizaram análise de sensibilidade para interpretar os resultados dos modelos desenvolvidos. Os três primeiros trabalhos fizeram a análise de sensibilidade como proposto por Fish e Blodgett (2003). Enquanto que Chang (2005) procedeu similarmente a Tong e Hung (2002) e Çodur e Tortum (2015) admitiram os resultados gerados pelo *software* Alyuda Neuro Intelligence.

Por outro lado, Abdel-Aty e Abdelwahab (2004) simularam todas as combinações dos fatores de entrada binários e quinze níveis de velocidade totalizando 61440 padrões, para compreender o relacionamento entre os fatores de risco e a gravidade de lesão do condutor.

Mais recentemente, Zeng *et al.* (2016a) e Zeng *et al.* (2016b), baseando-se em Setiono e Thong (2004), propuseram um método de extração e interpretação de regras das RNA. Os autores procedem ao estabelecimento das regras e de suas condições, bem como de suas consequências que tornam os resultados interpretáveis e passíveis de geração de conclusões.

Embora não tenha sido empregado nos artigos analisados, outro método de avaliação da importância dos parâmetros de entrada no resultado das RNA é o proposto por Howes e Crook (1999). Os autores propuseram o cálculo de índices para analisar a importância relativa das variáveis de entrada, sendo eles: influência geral (GI), influência específica (SI) e influência potencial (PI). GI é utilizado para avaliar a influência geral dos parâmetros de entrada, SI para a influência específica de parâmetros de entrada individuais nos resultados das RNA em questão e, PI para a influência potencial de cada parâmetro de entrada na resposta da rede.

Refere-se ainda que, Sohn e Lee (2003) e Alikhani *et al.* (2013) não procederam à avaliação da importância relativa das variáveis explicativas, tendo avaliado, tão somente as medidas de

desempenho dos modelos desenvolvidos. Xie *et al.* (2007), por sua vez, procedeu à análise de sensibilidade apenas das redes neurais Bayesianas.

Com relação a abordagem de redes neurais Bayesianas, foram identificados três trabalhos. O primeiro deles, de Xie *et al.* (2007), fez comparação desta abordagem com a de RNA e modelo de regressão com distribuição binomial negativa. O modelo de RNB contou com apenas uma camada oculta com 5 neurônios. E o treinamento foi baseado no algoritmo Evolucionário de Monte Carlo (EMC). Os resultados do estudo indicaram que o modelo estatístico teve pior desempenho que os modelos de redes neurais e ainda, que o modelo RNB teve o melhor desempenho entre todos. Os autores ainda afirmaram que a incorporação da teoria de inferência Bayesiana reduz o problema de *overfitting* das redes neurais. O estudo também avaliou a influência de cada variável explicativa do modelo RNB, utilizando-se da análise de sensibilidade proposta por Fish e Blodgett (2003).

Enquanto o modelo de Xie *et al.* (2007) objetivou a previsão de frequência de acidentes, Oña *et al.* (2011) também recorreram às redes Bayesianas mas para a análise de acidentes por severidade. A contribuição de cada variável explicativa foi feita por inferência. Pouco depois, Oña *et al.* (2013b) investigaram o efeito do uso de análise de classes latentes associado a redes Bayesianas na classificação de acidentes por grau de lesão. Análogo ao estudo anterior, o contributo de cada variável de entrada foi obtido por inferência. Para os autores, os resultados mostraram que o uso combinado das duas técnicas é interessante, já que revela informações adicionais que não teriam sido obtidos sem a clusterização dos dados brutos, no entanto, a interpretação deve ser cuidadosa.

#### **A.4.2. Árvores de Decisão**

Foram identificados sete estudos com abordagem de árvores de decisão. No primeiro deles, Sohn e Lee (2003) utilizaram diversos classificadores, a saber: RNA, AD e algoritmos de fusão e conjuntos (algoritmo *Dempster-Shafer*, fusão Bayesiana, fusão logística, fusão *arcing* e *bagging* e algoritmo *k-means*). Os resultados denotaram que, embora o classificador AD tenha tido o menor poder de discriminação, apresentou acurácia superior aos demais classificadores quando associado ao algoritmo de clusterização. Como o foco do estudo foi a comparação entre as técnicas, foram tidas em conta apenas as medidas de desempenho dos modelos, não se avaliou a influência das variáveis de resposta sobre a severidade do acidente.

Kwon *et al.* (2015) aplicaram classificadores Naive Bayes, árvores de decisão e modelo de regressão logística binária (modelo *logit*) para análise da severidade de acidentes e fatores associados. Foi adotada uma árvore de decisão probabilística baseada em estatísticas Bayesianas. Tanto nas AD como nos classificadores Naive Bayes foram determinados os *scores* de cada variável de entrada, a métrica K2 BD (*Bayesian Dirichlet*), possibilitando ranquear os fatores de risco e verificar a importância relativa de cada um.

Oña *et al.* (2013a) recorreram às árvores de decisão com o uso de diferentes algoritmos: ID3, C4.5 e CART. Além da comparação dos resultados das diferentes abordagens, que demonstrou a superioridade do algoritmo CART, os autores investigaram a viabilidade de extração de regras das árvores de decisão e determinação da importância das variáveis independentes.

Chang e Chen (2005) utilizaram-se do modelo de regressão com distribuição binomial negativa e das árvores de classificação e regressão para previsão de frequência de acidentes por segmento rodoviário por ano. Os resultados demonstraram que uso de CART é uma boa alternativa frente ao modelo NB. Já com o propósito de análise de acidentes por severidade, Chang e Wang (2006) também utilizaram CART. Em ambos os estudos, o arranjo da árvore permitiu visualizar facilmente a importância de cada variável explicativa.

Ainda com o propósito de análise de acidentes por severidade, Kashani e Mohaymany (2011) valeram-se das CART. Os autores afirmaram ser este método aderente ao objetivo da análise e possuir facilidade de compreensão e interpretação devido à natureza gráfica de seus resultados. Analogamente a Oña *et al.* (2013a), também foi determinada a importância relativa das variáveis explicativas por meio do índice VIM (*Variable importance index*).

Recentemente, Chen *et al.* (2016) utilizaram de CART no problema classificação de acidentes por gravidade de lesão de condutores em acidentes de capotagem. A técnica foi utilizada para ranquear a importância relativa e identificar as variáveis significativas para a modelagem. A partir disso, o processo de modelagem foi conduzido com recurso à técnica SVM.



#### **A.4.3. Máquina de Vetores de Suporte**

Apenas dois estudos com abordagem de máquina de vetores de suporte foram detectados. Li *et al.* (2008) modelou a previsão de frequência de acidentes por meio de SVM e modelo de regressão com distribuição binominal negativa. Os resultados indicaram o desempenho superior do modelo SVM frente à modelagem estatística. Segundo os autores, os resultados auferidos também são similares ou superiores a mesma modelagem realizada com uso de RNA. Por fim, similar à limitação das RNA, o modelo SVM também tem característica “caixa-preta”, o que demandou que os autores utilizassem a análise de sensibilidade, proposta por Fish e Blodgett (2003), para determinação da importância relativa das variáveis.

O outro trabalho, de Chen *et al.* (2016), recorreu a esta técnica para a análise de acidentes segundo a severidade destes. Os autores investigaram o uso de função polinomial e função de raio gaussiano na modelagem, tendo constatado que o primeiro tipo teve melhor desempenho, considerando-se a taxa de acerto na validação e que este último modelo é mais suscetível a *over-fitting*. Ainda assim, o modelo SVM função polinomial não conduziu a resultados muito bons para acidentes com lesão incapacitante ou fatalidade. No que se refere a influência das variáveis explicativas, procedeu-se à análise de sensibilidade em dois estágios: i) alteração das variáveis explicativas e registro do impacto de cada alteração (FISH & BLODGETT, 2003); ii) similar a análise de pseudo-elasticidade (KIM *et al.*, 2007), a variação da probabilidade é calculada, e então, tem-se a influência de cada variável na severidade do acidente.

#### **A.4.4. Programação Genética**

Das e Abdel-Aty (2010) utilizaram programação genética linear para modelar a relação de fatores viário-ambientais e operacionais e a severidade dos acidentes, para três tipos. Preliminarmente à modelagem, foi realizada a clusterização dos dados. Em seguida, vários modelos foram gerados por cluster, tendo sido selecionado o melhor dentre eles por meio do WHR (*Weighted Hit Rate*), índice associado à taxa de acerto. Segundo os autores, os modelos apresentaram erros menores que outros classificadores tradicionais. Os resultados do melhor modelo associado a cada cluster permitiu a identificação dos principais fatores contribuintes e sua forma de associação (positiva ou negativa).

Os mesmos autores desenvolveram trabalho de modelagem de frequência de acidentes e severidade de acidentes de colisão traseira com programação genética. Das e Abdel-Aty (2011) procederam, inicialmente, à clusterização dos dados, o que tornou a análise mais estável. Seguidamente, um modelo de classificação foi desenvolvido para a análise de acidentes por severidade, enquanto que um modelo de regressão foi utilizado para a previsão de frequência de acidentes. No modelo de severidade de acidentes, os melhores modelos gerados permitem identificar quais as variáveis mais importantes. Ao passo que, no modelo de frequência de acidentes, utilizou-se a análise de sensibilidade relativa (proposta por Saltelli *et al.*, 2000) para avaliar quais variáveis têm maior impacto na variação dos resultados.

#### **A.4.5. Demais Técnicas**

As demais técnicas foram utilizadas de forma associada às técnicas já revisadas. Sohn e Lee (2003) utilizaram, como já referido, algoritmos de fusão e conjuntos (algoritmo *Dempster-Shafer*, fusão Bayesiana, fusão logística, fusão *arcing* e *bagging* e algoritmo *k-means*). Comparativamente, o poder de discriminação da abordagem bayesiana foi superior aos classificadores individuais (RNA e AD) e demais técnicas de fusão, ao passo que o uso de algoritmos para fusão de classificadores melhorou o desempenho do modelo. O algoritmo *Dempster-Shafer* gerou melhores resultados tanto individualmente quanto na utilização junto às redes neurais e árvores de decisão. Os algoritmos de conjunto também apresentaram melhorias nos resultados, mas inferiores aos constatados com a clusterização. Por fim, constatou-se que o agrupamento dos dados em *clusters* resultou no melhor desempenho do modelo.

Abdel-Aty e Abdelwahab (2004), além de RNA multicamadas, fez uso de redes neurais com teoria da ressonância adaptativa *fuzzy* (ARTMAP) para classificação de acidentes por severidade na Flórida Central. Com consequência, o modelo de redes neurais MLP logrou melhores resultados frente ao modelo ARTMAP. Os autores investigaram o relacionamento de diversas variáveis explicativas com a gravidade de lesão dos motoristas, mas apenas para o modelo MLP de melhor desempenho.


Alikhani *et al.* (2013), além de RNA, utilizou sistema *neuro-fuzzy* (ANFIS) e para clusterização: algoritmos *k-means* e *self-organizing maps* (SOM), na análise de acidentes por severidade no Irã. Os resultados obtidos com os modelos individuais demonstraram a inferioridade destes em

relação à classificação dos modelos utilizando *clusters*. Os melhores resultados foram verificados no caso de RNA associado a clusterização SOM. Os autores ainda concluíram que a abordagem de classificação agrupada por *clusters* é útil para classificação de dados com altas variações observadas, como é o caso dos dados de acidentes do Irã.


As considerações sobre o uso de classificador Naive Bayes e análise de classes latentes já foram tecidas na sintetização dos trabalhos de Kwon *et al.* (2015) e Oña *et al.* (2013b).

#### A.4.6. Modelos de Previsão de Acidentes por Severidade

Foram identificados 13 modelos de previsão/classificação de acidentes por severidade ou gravidade de lesão de ocupantes. Na Figura A.7 está apresentada a proporção de publicações por país, considerando a indicação de residência do primeiro autor. Enquanto que na Figura A.8 consta a distribuição das publicações por técnica de AM.



**Figura A.7** - Países com artigos de modelagem de acidentes por severidade selecionados



**Figura A.8**- Técnicas utilizada na modelagem de acidentes por severidade

Nota-se a predominância de trabalhos de pesquisadores dos Estados Unidos, com quase um terço dos trabalhos. Metade dos trabalhos americanos têm, pelo menos, um autor em comum. Também com expressividade se apresenta a Espanha, donde todos os artigos selecionados têm o mesmo primeiro autor, denotando uma sequência de estudos nesta temática pelo mesmo grupo de pesquisa. Ainda possuem trabalhos nesta área, em ordem de relevância: Coreia do Sul, Irã, China e Taiwan, todos países asiáticos que, somados representam quase metade dos trabalhos.

Quanto às técnicas de modelagem de acidentes por severidade, é perceptível o predomínio de RNA, seguida de CART. Agrupando-se RNA e RNB e ainda, CART e AD, cada grupo ficaria com 32% do total de trabalhos. As demais técnicas são menos expressivas e, em sua maioria, complementam as técnicas dominantes. Na Tabela A.7 estão apresentadas a quantidade de dados e área de estudo de cada modelo.

**Tabela A.7-** Quantidade de dados e área de estudo de cada modelo de previsão de acidentes por severidade

Referência	Técnica	Dados	Área de estudo
<b>Sohn e Lee (2003)</b>	RNA; AD; AFC	11564 acidentes ocorridos em 1996	Vias urbanas de Seul
<b>Abdel-Aty e Abdelwahab (2004)</b>	RNA; ARTMAP; MP	7891 registros de acidentes com 17647 motoristas envolvidos, entre 1996 e 1997	Vias rurais e urbanas da Flórida Central
<b>Chang e Wang (2006)</b>	CART	12604 dados de acidentes no ano de 2001, envolvendo 29673 veículos e pedestres.	Vias urbanas e rodovias de Taipé
<b>Delen et al. (2006)</b>	RNA	30358 registros entre 1995 e 2000 (0,85% dos registros feitos por autoridades policiais)	Amostra de acidentes em todo o território americano, sem restrição geográfica. Foram considerados acidentes em áreas urbanas e rurais.
<b>Das e Abdel-Aty (2010)</b>	PG	104952 acidentes, distribuídos em três tipos: colisão em movimento de conversão (44088), colisão frontal (3709) e colisão traseira (57155) na Flórida, entre 2004 e 2006	Vias expressas na Flórida
<b>Oña et al. (2011)</b>	RNB	1536 registros de acidentes em rodovias rurais da Espanha entre 2003 e 2005	Rodovias rurais de pista simples de Granada/Espanha, excluídas interseções.
<b>Kashani e Mohaymany (2011)</b>	CART	21025 registros de acidentes (um para cada ocupante lesionado) entre 2006 e 2008	Rodovias de pista simples do Irã
<b>Oña et al. (2013a)</b>	CART; AD	1801 acidentes em rodovias de pista simples da Espanha, envolvendo apenas um veículo entre 2003 e 2009	Rodovias rurais de pista simples de Granada/Espanha, excluídas interseções.

Referência	Técnica	Dados	Área de estudo
Oña <i>et al.</i> (2013b)	LCA; RNB	3229 acidentes em rodovias rurais, entre 2005 e 2008. Apenas acidentes envolvendo 1, 2 ou 3 veículos.	Rodovias rurais de pista simples de Granada/Espanha, excluídas interseções.
Alikhani <i>et al.</i> (2013)	RNA; ANFIS; AK; SOM	7035 registros de acidentes em 2011, no Irã	Rodovias do Irã
Zeng e Huang (2014)	RNA; ML	53732 acidentes envolvendo dois veículos (107464 partes envolvidas) em rodovias da Flórida no ano de 2006	Rodovias rurais da Flórida
Kwon <i>et al.</i> (2015)	CNB; AD; ML	1350598 registros de acidentes em rodovias da Califórnia, envolvendo veículos leves, entre 2004 e 2010	Rodovias da Califórnia
Chen <i>et al.</i> (2016)	CART; SVM	3106 acidentes de tombamento/capotagem, envolvendo 3158 veículos/condutores, entre 2010 e 2011	Vias urbanas e rodovias em Novo México (EUA)

O menor número de registros de acidentes utilizado para modelagem foi 1536, empregado por Oña *et al.* (2011), na Espanha. Doutro lado, Das e Abdel-Aty (2010) utilizaram 104952 dados de acidentes viários na Flórida para o desenvolvimento dos modelos. Sohn e Lee (2003), Chang e Wang (2006), Alikhani *et al.* (2013) e Zeng e Huang (2014) utilizaram apenas um ano de registros de acidentes. Em contraposição, Kwon *et al.* (2015) realizaram a modelagem com uma série histórica de 6 anos.

Nem todos os estudos explicitaram a delimitação da área de estudo. Por exemplo, Sohn e Lee (2003) tiveram como área de estudo as vias urbanas de Seul, o que, supõe-se, inclui vias locais, coletoras, arteriais e expressas. Abdel-Aty e Abdelwahab (2004), Chang e Wang (2006) e Chen *et al.* (2016) desenvolveram modelos baseados em dados de vias urbanas e rodovias da Flórida Central/EUA, de Taipé/Taiwan e Novo México/EUA, respectivamente.

Das e Abdel-Aty (2010) utilizaram dados apenas de vias expressas (*multilane arterial corridors*) na Flórida e realizaram a divisão dos dados em 4 *clusters*, de acordo com a extensão das vias. Kashani e Mohaymany (2011) tiveram como objeto de estudo rodovias de pista simples do Irã, enquanto que Alikhani *et al.* (2013) desenvolveram modelos para rodovias do Irã, sem restrição de tipo. Zeng e Huang (2014) e Kwon *et al.* (2015) analisaram rodovias rurais da Flórida e rodovias da Califórnia, respectivamente, sem mais especificações.

Oña *et al.* (2011), Oña *et al.* (2013a) e Oña *et al.* (2013b) analisaram acidentes ocorridos em rodovias de pista simples de Granada, excluídas as interseções. Oña *et al.* (2013b) procederam

à clusterização dos dados antes da modelagem, resultando em 4 *clusters*: C1 (colisões em rodovias com acostamento), C2 (saída de pista ou acidentes envolvendo pedestres em rodovias com acostamento), C3 (acidentes em rodovias sem acostamento) e C4 (saída de pista ou acidentes envolvendo pedestres em rodovias sem acostamento).

Delen *et al.* (2006) não fizeram delimitação geográfica das vias a serem estudadas, tendo considerado todos os registros de um banco de dados que representa 0,85% dos registros reportados à polícia nos EUA entre 1995 e 2000. Assim, estes dados foram compilados e tratados com uma amostra representativa de todos os acidentes registrados por autoridade policial.


Todos os modelos desenvolvidos utilizaram os dados sem agrupá-los e associá-los a trechos das rodovias, ou seja, sem realizar a segmentação das rodovias e alocação dos dados por trecho homogêneo. A segmentação é essencial quando se trata de modelagem de frequência de acidentes.

Na Tabela A.8 estão apresentadas as variáveis independentes (*inputs*) e de saída de cada modelo. O modelo com o menor número de *inputs* é o de Sohn e Lee (2003), com 6, e o modelo com mais variáveis de entrada é Kwon *et al.* (2015) com 25. As variáveis utilizadas nos modelos podem ser enquadradas em quatro classes: fatores humanos, fatores viário-ambientais, fatores veiculares e caracterização do acidente.

Apresenta-se na Figura A.9 a distribuição dos grupos de variáveis, considerando todos os modelos, em termos do número de variáveis por grupo, quantidade de modelos em que foram empregadas e total de ocorrência destas nos modelos. No eixo das abscissas consta o número de modelos que incorporaram cada grupo de variáveis, ao passo que o eixo das ordenadas corresponde ao número total de variáveis de cada grupo. Por fim, o tamanho das bolhas é dado pelo número total de ocorrências das variáveis de cada grupo.


Denota-se que os fatores viário-ambientais além de terem sido empregados em todos os modelos, possuem o maior número de ocorrência de suas variáveis, com quase 45% do total. As variáveis de caracterização do acidente estão presentes em 11 dos 13 modelos analisados e auferem a terceira maior proporção de ocorrência. Os fatores humanos foram incorporados em 9 modelos e figuram como segundo grupo de maior frequência de variáveis. Os fatores

veiculares, por sua vez, foram utilizados em 8 modelos e o total proporcional de ocorrência de suas variáveis foi pouco relevante, menos de 7%.



**Figura A.9-** Distribuição das variáveis explicativas por emprego nos estudos, número de variáveis e número de ocorrências, na modelagem de acidentes por severidade.

É perceptível, portanto, a importância dada aos fatores viário-ambientais nos modelos de previsão de acidentes por severidade. As variáveis relativas à caracterização do acidente também lograram papel de destaque na modelagem, seguidas dos fatores humanos. Os *inputs* utilizados em todos os modelos foram agrupados por objetivo e similaridade, resultando em 58 variáveis de entrada. Para compreender melhor a distribuição destas variáveis dentro dos grupos, são apresentadas as Figuras A.10, A.11, A.12 e A.13.



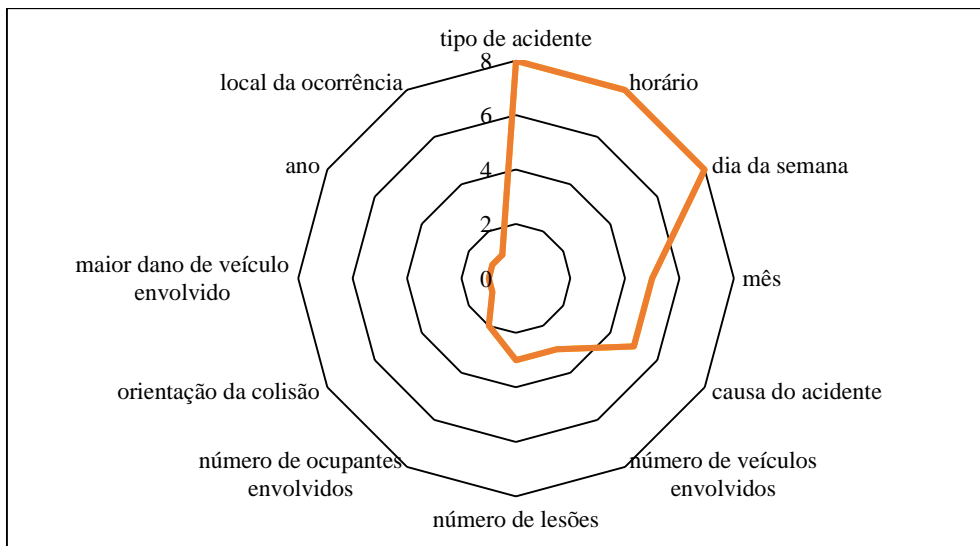
**Figura A.10 -** Distribuição dos fatores viário-ambientais na modelagem de acidentes por severidade

**Tabela A.8-** Variáveis explicativas e variáveis de saída de cada modelo de previsão de acidentes por severidade


Referência	Principais variáveis explicativas	Variáveis de saída
<b>Sohn e Lee (2003)</b>	6 variáveis: largura da via, formato do carro, tipo de acidente, velocidade anterior ao acidente, direção perigosa, dispositivos de proteção.	Dois classes: lesão corporal ou danos materiais.
<b>Abdel-Aty e Abdelwahab (2004)</b>	12 variáveis: idade do condutor, sexo, uso de álcool, uso de cinto de segurança, tipo de veículo, ponto de impacto, velocidade do veículo, uso do solo, iluminação, hora de pico, condições climáticas, trecho da via.	Quatro classes: sem lesão; possível lesão; lesão evidente; lesão incapacitante/fatalidade
<b>Chang e Wang (2006)</b>	20 variáveis explicativas: mês, hora, dia da semana, clima, iluminação, superfície do pavimento, obstrução da via, trecho da via (interseção, reta, travessia de pedestre), tipo de controle, divisão da via, limite de velocidade, sexo, idade, condição do envolvido (motorista com habilitação, motorista sem habilitação, passageiro), sistema de restrição, condição de sobriedade, tipo de veículo, ação do envolvido (passando, convergindo à direita, veículo parado, etc), tipo de colisão, circunstância contributiva.	Três classes: sem lesão, lesão ou fatalidade
<b>Delen <i>et al.</i> (2006)</b>	De 150 variáveis iniciais foram selecionadas 17: idade, sexo, uso de álcool ou drogas, idade do veículo, tipo de veículo, sistema de restrição, acidente em rodovia interestadual, fase do dia, condição da superfície do pavimento, veículo que colidiu, veículo que foi colidido, tipo de impacto, capotagem, orientação da colisão, acidente sexta à noite, acidente sábado à noite, acidente domingo à noite)	Cinco níveis de gravidade de lesão: sem lesão, possível lesão, lesão não incapacitante, lesão incapacitante e fatalidade.
<b>Das e Abdel-Aty (2010)</b>	57 variáveis, das quais agrupando-se resultam 21 variáveis: largura da via, limite de velocidade, condição do via, visibilidade, largura de acostamento e calçada, condição da superfície da via, fase do dia, iluminação, curvatura vertical, presença de estacionamento, tipo de superfície, tipo de acostamento, divisão central, presença de curva, volume diário médio, horário de pico de manhã em dia de semana, horário de pico a tarde em dia de semana, sábado ou domingo à noite, fora do horário de pico, condição do pavimento, trecho da via (segmento, interseção ou acesso).	Dois abordagens, cada uma com duas saídas - i) ileso ou ferido (I/F); ii) possível lesão/lesão não incapacitante ou lesão incapacitante/fatalidade (LN/LI)
<b>Oña <i>et al.</i> (2011)</b>	18 variáveis explicativas: tipo de acidente, fatores climáticos, causa, dia, mês, horário, idade, sexo, iluminação, número de lesões, número de ocupantes envolvidos, pavimentação do acostamento, sinalização horizontal, largura de faixa, largura da pista, tipo de acostamento, número de veículos envolvidos, visibilidade.	Dois classes: Lesão leve ou fatalidade e lesão grave
<b>Kashani e Mohaymany (2011)</b>	10 variáveis: sexo, cinto de segurança, causa do acidente, tipo de colisão, trecho da via, iluminação, condições climáticas, superfície da pista, tipo de acostamento, local da ocorrência (pista, acostamento, às margens, no meio, fora da via, outro)	Três classes: lesão leve, lesão grave ou fatalidade



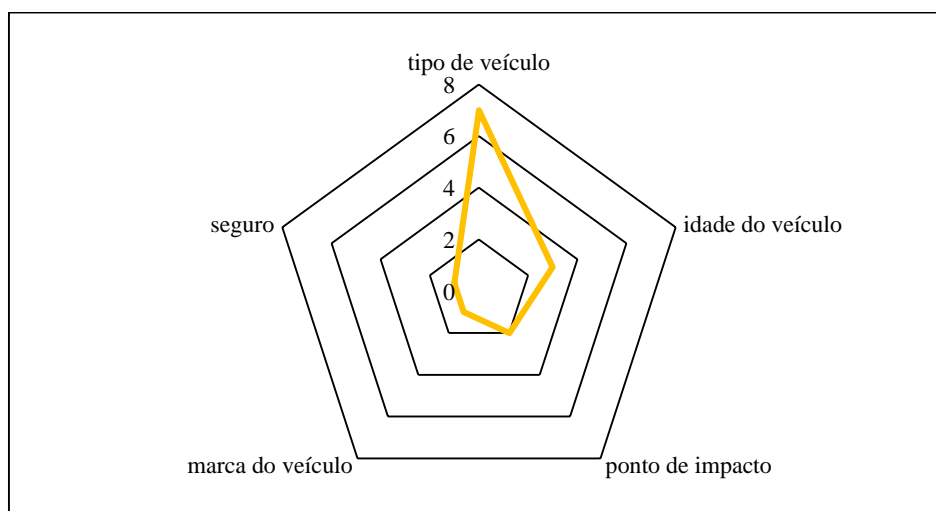
<b>Referência</b>	<b>Principais variáveis explicativas</b>	<b>Variáveis de saída</b>
<b>Oña <i>et al.</i> (2013a)</b>	19 variáveis explicativas: tipo de acidente, fatores climáticos, causa, dia, mês, horário, idade, sexo, iluminação, número de lesões, número de ocupantes envolvidos, sinalização horizontal, largura de faixa, largura da pista, tipo de acostamento, barreiras de segurança, acostamento pavimentado, tipo de veículo, visibilidade.	Duas classes: Lesão leve ou fatalidade e lesão grave
<b>Oña <i>et al.</i> (2013b)</b>	18 variáveis explicativas: tipo de acidente, fatores climáticos, causa, dia, mês, horário, idade, sexo, iluminação, número de lesões, número de ocupantes envolvidos, pavimentação do acostamento, sinalização horizontal, largura de faixa, largura da pista, tipo de acostamento, número de veículos envolvidos, visibilidade.	Duas classes: Lesão leve ou fatalidade e lesão grave
<b>Alikhani <i>et al.</i> (2013)</b>	6 variáveis: Sexo, acostamento, direção de fluxos na rodovia, tipo de rodovia, cinto de segurança, limite de velocidade.	Duas classes: vítimas ou danos materiais
<b>Zeng e Huang (2014)</b>	16 variáveis: idade do condutor, sexo, uso de álcool ou drogas, equipamentos de segurança, falha do condutor, ano do veículo, tipo do veículo, razão de velocidade, ponto de impacto, dia da semana, uso do solo, iluminação, condições climáticas, superfície da pista, visibilidade, tipo de rodovia.	Quatro classes: sem lesão/apenas danos materiais, possível lesão, lesão não incapacitante, lesão incapacidade/fatalidade
<b>Kwon <i>et al.</i> (2015)</b>	De 100 variáveis disponíveis, 25 foram investigadas: falha do condutor, fadiga, uso de celular, movimento precedente da colisão, sobriedade, infração, idade, sexo, raça, marca do veículo, idade do veículo, superfície da pista, condição de tráfego, ano, mês, dia da semana, hora, população da localidade, condições climáticas, tipo de colisão, interseção, rodovia estadual, seguro, iluminação, outros fatores associados.	Duas classes: Fatalidade ou apenas danos materiais
<b>Chen <i>et al.</i> (2016)</b>	De 22 variáveis iniciais, foram selecionadas 18: condições climáticas, número de veículos envolvidos, tipo de rodovia, maior dano de veículo envolvido, localização do acidente (proximidade de uma interseção), horário, residência do condutor, restrição de habilitação, pavimentação da rodovia, superfície da pista, controle de tráfego, número de faixas disponíveis, tipo de veículo, ação do veículo, uso de cinto de segurança pelo motorista, idade do condutor, sexo do condutor, motorista sob influência	Três classes: sem lesão, lesão não incapacitante e lesão incapacitante ou fatalidade; Duas classes: lesão não incapacitante e lesão incapacitante ou fatalidade.



**Figura A. 11-** Distribuição das variáveis de caracterização do acidente na modelagem de acidentes por severidade



**Figura A. 12 -** Distribuição dos fatores humanos na modelagem de acidentes por severidade



**Figura A. 13-** Distribuição dos fatores veiculares na modelagem de acidentes por severidade

Os gráficos tipo radar são interessantes por, de forma fácil e visual, possibilitarem a identificação das variáveis de entrada mais utilizadas, segundo cada agrupamento. No caso dos fatores viário-ambientais, destacam-se: condições climáticas, iluminação, trecho da via, tipo de acostamento. A primeira variável pode ter, por exemplo, como opção: céu limpo, nublado, chuva leve, chuva forte, tempestade, neve. A iluminação pode ser descrita como: luz do dia, suficiente, insuficiente, sem iluminação. O trecho da via tem como resposta: reta, curva, interseção, travessia de pedestre. E o tipo de acostamento pode ser pavimentado ou não pavimentado.

Tipo de acidente, horário e dia da semana são as variáveis de maior destaque na caracterização do acidente. Na tipologia do acidente, os autores utilizaram tanto a classificação de acidentes (colisão traseira, colisão frontal, capotagem, etc) quanto o envolvimento de veículos (colisão entre moto e bicicleta, colisão entre dois veículos, colisão envolvendo pedestre, colisão com animal, etc). Refere-se ainda que, esta variável não está presente apenas em cinco modelos: Abdel-Aty e Abdelwahab (2004), Alikhani *et al.* (2013), Zeng e Huang (2014), Das e Abdel-Aty (2010), e Chen *et al.* (2016), sendo que os dois últimos trataram da análise de tipos específicos de acidentes: colisão traseira e tombamento/capotagem, respectivamente, impossibilitando a incorporação desta variável. O dia da semana foi tratado em alguns modelos como binário, tratando especificamente de sexta-feira, sábado ou domingo, com resposta positiva ou negativa para a ocorrência do acidente.


Nos fatores humanos, as variáveis mais expressivas foram: sexo, idade e uso de cinto de segurança. O sexo foi o *input* mais utilizado entre os modelos, apenas Sohn e Lee (2003) e Das e Abdel-Aty (2010) não consideraram esta variável.

Quanto aos fatores veiculares, apenas tipo de veículo e idade do veículo se mostraram representativas. Na tipologia de veículo enquadraram-se: carro de passeio, van, caminhonete/caminhão pequeno, caminhão pesado, motocicletas, outros.

Por fim, a Figura A.14 auxilia na análise geral da distribuição das variáveis nos modelos. Das 57 variáveis resultantes do agrupamento por similaridade, 18 tiveram apenas uma ocorrência, denotando serem variáveis insignificantes por constarem em só um modelo. Também foram identificadas 9 variáveis com somente duas ocorrências, o que não as torna expressivas. Assim,

considerando também a necessidade de redução dimensional para boa apresentação visual dos resultados no gráfico tipo radar, foram excluídas as variáveis com uma ou duas ocorrências.

As variáveis de maior destaque foram: sexo, idade, condições climáticas, iluminação, uso do cinto de segurança, tipo de acidente, horário, dia da semana, trecho da via, tipo de acostamento e tipo de veículo. Os fatores humanos, por meio das variáveis sexo, idade e uso de cinto de segurança, figuraram nas primeiras posições do *ranking* de ocorrência de variáveis nos modelos analisados. Os fatores viário-ambientais, em convergência ao constatado individualmente nos modelos, são os principais na modelagem. A proporção média destes fatores nos modelos foi de 43,85% e dentre as 11 variáveis mais importantes aqui elencadas na análise geral, têm uma parcela de quase 37%. Isso confirma que essas variáveis não só estão em maior número, como ocorrem entre as principais. Características do acidente (tipo de acidente, horário e dia da semana) possuem a mesma proporção que os fatores humanos, no entanto, com menos expressividade que estes. Já no nível veicular, apenas uma variável foi verificada entre as principais, o tipo de carro, e na última colocação do *ranking*.




**Figura A.14-** Distribuição das variáveis de entrada de todos os modelos de previsão de acidentes por severidade

O ranqueamento evidencia a importância das variáveis para a modelagem, refletida em recorrência de utilização destas no desenvolvimento de modelos de previsão de acidentes por severidade. No entanto, tais escolhas podem ter sido pautadas em análise preliminar de dados,

conveniência ou mesmo, inexistência de dados complementares. De todo modo, essa análise e sistematização dos resultados fornece indicativos para outros trabalhos nesta temática.

Agora tratando-se de variáveis de saída, os modelos avaliados tiveram diferentes variáveis-resposta segundo duas, três, quatro ou cinco classes de severidade. Na Figura A.15 é mostrada a proporção de cada tipo de abordagem.



**Figura A. 15-** Classes-resposta dos modelos de previsão de acidente por severidade

Como é possível observar, a maior parte dos estudos recaem em classificação binária da severidade do acidente. Sohn e Lee (2003) utilizaram como saída: “lesão corporal” ou “danos materiais”. Das e Abdel-Aty (2010) desenvolveram modelos em duas etapas: classificando inicialmente em “ileso” ou “ferido” e, no caso dos feridos, retornando em “possível lesão/lesão não incapacitante” ou “lesão incapacitante/fatalidade”. Oña *et al.* (2011), Oña *et al.* (2013a) e Oña *et al.* (2013b) adotaram como variáveis de saída: “lesão leve” ou “lesão grave e fatalidade”. Alikhani *et al.* (2013) desenvolveram a modelagem de forma que a severidade resultante fosse: “danos materiais” ou “vítimas”. Kwon *et al.* (2015) por sua vez, tiveram como variável-resposta: “danos materiais” ou “fatalidades”.

Chang e Wang (2006), Kashani e Mohaymany (2011) e Chen *et al.* (2016) desenvolveram modelos com três possibilidades de classificação. Os dois primeiros trabalhos tiveram como variáveis de saída: “lesão leve” ou “lesão grave” ou “fatalidade”. Enquanto que Chen *et al.* (2016) classificaram em: “sem lesão/lesão não incapacitante” ou “lesão incapacitante” ou “fatalidade”. Os autores ainda procederam à modelagem com classificação binária: “lesão não incapacitante” ou “lesão incapacitante e fatalidade”, constatando-se que esta última abordagem, com dados agrupados, conduziu aos melhores resultados. Kashani e Mohaymany (2011)

também vislumbrando melhores resultados, converteu o problema de tríplice classificação em quatro modelos de classificação binária.

Abdel-Aty e Abdelwahab (2004) e Zeng e Huang (2014) desenvolveram os modelos como um problema de multiclassificação, tendo como saída: “sem lesão/apenas danos materiais” ou “possível lesão” ou “lesão não incapacitante” ou “lesão incapacidade/fatalidade”.

Delen *et al.* (2006) foram os únicos a desenvolver modelos com cinco possibilidades de classificação, a saber: “sem lesão” ou “possível lesão” ou “lesão não incapacitante” ou “lesão incapacitante” ou “fatalidade”. Ainda que o problema fosse multicategórico, após verificação inicial e constatação de resultados pouco razoáveis, os autores converteram cinco classes de predição em oito modelos binários de classificação de severidade.

Duas abordagens são comumente utilizadas na redução de problemas multiclases em classificadores binários. A primeira é o método chamado *one-vs-all* (OVA) onde cada classe é, separadamente, comparada às demais classes; desta forma, para um problema de classe N, resultam N classificadores binários. A segunda abordagem é chamada *all-vs-all* (AVA) onde são criadas todas as combinações binárias possíveis, o que para um problema de classe N, resulta em  $(N!/((N-2)!*2!))$  classificadores binários (DELEN *et al.*, 2006; KASHANI & MOHAYMANY, 2011).

Fürnkranz (2002) afirmou que o desempenho da técnica AVA foi superior ao da OVA. Rifkin e Klautau (2004), no entanto, recorrendo a uma ampla base de dados constatou que a abordagem OVA, mais simples, é tão precisa como a abordagem AVA. É factível, portanto, que o pesquisador compreenda os benefícios e limitações de cada abordagem, procedendo ao uso consciente de uma delas ou propondo solução alternativa.

Para finalizar a sistematização dos modelos de previsão de acidentes por severidade, são apresentados na Tabela A.9 as medidas de desempenho de cada modelo, conjunto de dados para modelagem e *software* utilizado.

**Tabela A.9 - Variáveis explicativas e variáveis de saída de cada modelo de previsão de acidentes por severidade**


Referência	Medidas de desempenho	Conjunto de dados	Software
<b>Sohn e Lee (2003)</b>	Acurácia - i) Árvore de decisão: 72,30%; ii) RNA: 70,86%; iii) Dempster-Shafer: 72,79%; iv) Bayesiano: 71,23%; v) fusão logística: 72,30%; vi) RNA (bagging): 72,70%; vii) Árvore de decisão (bagging): 74,78%; viii) RNA (cluster): 73,94; ix) Árvore de decisão (cluster): 76,10%	60% dos dados para treinamento e 40% para validação	SAS E-miner; Excel
<b>Abdel-Aty e Abdelwahab (2004)</b>	Acurácia i) RNA MLP: 73,5%; ii) RNA ARTMAP: 70,6%; iii) Probit ordenado: 61,7%	51,9% dos dados para treinamento e 48,1% para validação	Não informado
<b>Chang e Wang (2006)</b>	Acurácia máxima: 94,7% (treinamento)/96,4% (validação) para previsão de acidentes com lesão. No entanto, a taxa de acerto para acidentes fatais foi 0% no teste e validação	Amostra de teste para geração de árvore de teste e comparação dos resultados	Não informado
<b>Delen et al. (2006)</b>	Acurácia média: i) com cinco classes - 40,71% (treinamento)/40,73% (validação); ii) com classificadores binários - 78,44% (treinamento)/78,38% (validação). Acurácia máxima: i) com cinco classes -53,60% (treinamento)/53,78% (validação); ii) classificadores binários - 99,54% (treinamento)/99,52% (validação)	Validação cruzada de dez vezes	Não informado
<b>Das e Abdel-Aty (2010)</b>	Acurácia: 1 - colisão em movimento de conversão i) Cluster 1: 60,41% (I/F), 83,27% (LN/LI); ii) Cluster 2: 57,83% (I/F), 81,94% (LN/LI); iii) Cluster 3: 57,75% (I/F); iv) Cluster 4: 59,51% (I/F), 83,58% (LN/LI). 2 - colisão frontal i) Cluster 1: 70,19% (I/F), 84,53% (LN/LI); ii) Cluster 2: 61,71% (I/F), 84,53% (LN/LI); iii) Cluster 3: 61,89% (I/F), 82,10% (LN/LI); iv) Cluster 4: 63,25% (I/F), 81,75% (LN/LI). 3 - colisão frontal i) Cluster 1: 56,37% (I/F), 91,85% (LN/LI); ii) Cluster 2: 53,09% (I/F); iii) Cluster 3: 52,50% (I/F), 91,48% (LN/LI); iv) Cluster 4: 54,10% (I/F), 89,43% (LN/LI)	70% dos dados para treinamento e 30% para validação	Discipulus™
<b>Oña et al. (2011)</b>	- Melhores resultados: i) acurácia: 0,61 (treinamento)/0,59 (validação); ii) sensibilidade: 0,74 (treinamento)/ 0,65 (validação); iii) especificidade: 0,47 (treinamento)/ 0,53 (validação); iv) F-measure: 0,56 (teste)/0,58 (validação); v) ROC area: i) 0,62 (treinamento)/0,62 (validação)	2/3 dos dados para treinamento e 1/3 para validação. Dez diferentes esquemas de treinamento/validação foram executados, visando analisar o efeito da troca de dados de treinamento e validação	Weka

<b>Kashani e Mohaymany (2011)</b>	Acurácia média: - Modelo de três classes: 37,20% (treinamento)/34,06% (validação); - Modelos de classificação binária - i) modelo 1.1: 56,91% (treinamento)/58,32% (validação); ii) modelo 1.2: 59,06% (treinamento)/60,94% (validação); iii) modelo 2.1: 57,59% (treinamento)/60,72% (validação); iv) modelo 2.2: 44,43% (treinamento)/48,02% (validação)	70% dos dados para treinamento e 30% para validação	Não informado
<b>Oña et al. (2013a)</b>	- Melhores resultados: 1 - CART i) acurácia: 0,56; ii) sensibilidade: 0,54; iii) especificidade: 0,58; iv) ROC area: 0,57; 2 - C4.5 i) acurácia: 0,54; ii) sensibilidade: 0,55; iii) especificidade: 0,54; iv) ROC area: 0,54; 3 - ID3 i) acurácia: 0,53; ii) sensibilidade: 0,53; iii) especificidade: 0,52; iv) ROC area: 0,53	Validação cruzada de 10 vezes (Dados: 70% para treinamento e 30% para validação)	Weka
<b>Oña et al. (2013b)</b>	- Base de dados: 1 - Completa: i) acurácia: 0,60; ii) sensibilidade: 0,69; iii) especificidade: 0,52; iv) ROC area: 0,63; v) F-measure: 0,59; 2 - C1: i) acurácia: 0,64; ii) sensibilidade: 0,78; iii) especificidade: 0,56; iv) ROC area: 0,67; v) F-measure: 0,65; 3 - C2: i) acurácia: 0,58; ii) sensibilidade: 0,61; iii) especificidade: 0,45; iv) ROC area: 0,61; v) F-measure: 0,51; 4 - C3: i) acurácia: 0,59; ii) sensibilidade: 0,78; iii) especificidade: 0,71; iv) ROC area: 0,57; v) F-measure: 0,74; 5 - C4: i) acurácia: 0,55; ii) sensibilidade: 0,47; iii) especificidade: 0,37; iv) ROC area: 0,56; v) F-measure: 0,41	Não informado	Latent GOLD software
<b>Alikhani et al. (2013)</b>	- Acurácia máxima: i) ANFIS: 76,11%; ii) RNA: 77,26%; iii) ANFIS (k-means): 77,76%; iv) RNA (k-means): 79,53%; v) ANFIS (SOM): 77,47%; v) RNA (SOM): 81,81%	80% dos dados para treinamento e 20% para validação	SPSS; MATLAB
<b>Zeng e Huang (2014)</b>	- Modelo Logit Ordenado: i) acurácia - 0,5178 (treinamento)/0,5167 (validação); - Modelo RNA algoritmo CC: i) acurácia - 0,5503 (treinamento)/0,5484 (validação); - Modelo otimizado RNA algoritmo CC: i) acurácia: 0,5501 (treinamento)/0,5491 (validação)	80% dos dados para treinamento e 20% para validação	SPSS; MATLAB
<b>Kwon et al. (2015)</b>	Curva ROC: árvore de decisão supera os outros dois modelos (regressão logística e classificador Naive Bayes); Curva precisão vs. Acurácia: maior evidência do desempenho superior do modelo de árvore de decisão	70% dos dados foram aleatoriamente separados e utilizados para modelagem e os 30% restantes utilizados para validação	Microsoft SQL Server
<b>Chen et al. (2016)</b>	Melhores resultados de classificação correta - SVM função de raio gaussiano (60% dados para treinamento): i) três classes de severidade: 94,20% (treinamento)/45,76% (validação); ii) duas classes de severidade: 95,20% (treinamento)/53,92% (validação). - SVM função polinomial (60% dados para treinamento): i) três classes de severidade: 82,11% (treinamento)/50,91% (validação); ii) 83,69 (treinamento)/62,63% (validação)	Três divisões de dados: i) 60% (treinamento)/40% (validação); ii) 70% (treinamento)/30% (validação); iii) 80% (treinamento)/20% (validação)	Não informado




#### A.4.7. Modelos de Previsão de Frequência de Acidentes

Foram identificados 6 modelos de previsão/classificação de frequência de acidentes. Figura A.16 está apresentada a proporção de publicações por país, considerando a indicação de residência do primeiro autor. Na Figura A.17 apresenta-se a distribuição das publicações por técnica de AM.



**Figura A. 16-** Países com artigos de modelos de previsão de frequência de acidentes

As publicações identificadas concentram-se em apenas quatro países. Estados Unidos e Taiwan se destacam proporcionalmente, mesmo que com apenas dois trabalhos. Nos trabalhos americanos dois coautores são comuns, analogamente, nos dois estudos taiwaneses têm-se o mesmo primeiro autor. Denota-se então, que existe uma sequência de estudos realizados pelos mesmos grupos de pesquisa, um em cada país. Assim como nos trabalhos de modelagem de acidentes por severidade, a Ásia tem predominância na modelagem de frequência de acidentes.



**Figura A. 17-** Técnicas utilizada na modelagem de frequência de acidentes

Quanto às técnicas de modelagem de frequência de acidentes, nota-se a predominância de RNA, seguida é perceptível o predomínio de RNA, seguido de CART, RNB e SVM, com apenas uma publicação cada.

Na Tabela A.10 estão apresentadas a quantidade de dados e área de estudo de cada modelo.

**Tabela A.10** - Quantidade de dados e área de estudo de cada modelo de frequência de acidentes

Referência	Técnica	Dados	Área de estudo	Segmentação
Chang (2005)	RNA; NB	1338 acidentes com mortos ou feridos, entre 1997 e 1998	Rodovia rural de pista dupla em Taiwan	373 km segmentados em 498 trechos por sentido (entre 0,1km e 4,2 km), resultando num total de 996 segmentos
Chang e Chen (2005)	CART; NB	1075 acidentes com feridos ou mortos, entre 2001 e 2002	Rodovia rural de pista dupla em Taiwan	373 km segmentados em 742 trechos de extensão de 1 km, resultando num total de 1484 segmentos
Xie <i>et al.</i> (2007)	NB; RNA; RNB	122 acidentes em um período de 5 anos	Rodovias rurais de pista simples no Texas	307 km segmentados em 88 trechos (entre 1,11 km e 8,59 km)
Li <i>et al.</i> (2008)	NB; SVM	122 acidentes em um período de 5 anos	Rodovias rurais de pista simples no Texas	307 km segmentados em 88 trechos (entre 1,11 km e 8,59 km)
Çodur e Tortum (2015)	RNA	7285 acidentes (registros válidos) entre 2005 e 2012	Rodovias rurais de pista dupla em Ezurum (Turquia)	152 km segmentados em 16 trechos (entre 4 km e 18,4 km)
Zeng <i>et al.</i> (2016)	RNA	1612 acidentes entre 2002 e 2006	Rodovias de Hong Kong	310 km segmentados em 211 trechos (entre 0,15 km e 9,07 km)

O volume de dados de acidente empregado nos modelos de frequência de acidente é sensivelmente inferior à quantidade média de registros de acidentes utilizado para modelagem de acidentes por severidade. Xie *et al.* (2007) e Li *et al.* (2008) desenvolveram seus trabalhos nos mesmos trechos rodoviários, utilizando somente 122 registros de acidentes. Doutro lado, Çodur e Tortum (2015) utilizaram a maior quantidade de dados, 7285 acidentes.

Chang (2005) e Chang e Chen (2005) utilizaram uma série histórica de dados de 2 anos. Xie *et al.* (2007), Li *et al.* (2008) e Zeng *et al.* (2016) utilizaram 5 anos de dados de acidentes. Çodur e Tortum (2015), por sua vez, utilizaram dados num período de 8 anos. A utilização de séries históricas de dados de acidentes é mais evidente na modelagem de frequência, já que diversos trechos podem ter zero registro de acidentes e assim, gerar degradação do desempenho do modelo. Desta forma, o agrupamento dos dados por período pode amenizar tal efeito negativo.

Por se tratarem de modelos de previsão de frequência de acidentes, todos autores procederam à segmentação das rodovias para fins da modelagem. Chang (2005) e Chang e Chen (2005) estudaram as mesmas rodovias, mas com uma distinção: no primeiro procedeu-se à divisão de

segmentos rodoviários homogêneos enquanto que no segundo estudo a rodovia foi dividida em trechos de igual extensão. Chang (2005) utilizou como critério de homogeneidade dos trechos a inalteração das seguintes características: número de faixas, curvatura horizontal e inclinação vertical. No trabalho de Chang e Chen (2005) foram utilizados segmentos com 1 km de extensão cada. Neste estudo, a caracterização geométrica das seções foi estabelecida de acordo com as características predominantes no trecho. Por exemplo, se um segmento rodoviário é composto por inclinação de 1% em 800 m de extensão e inclinação de 3% dos 200 m restantes, será adotada a inclinação de 1% como característica de todo o segmento. Ambos os trabalhos tiveram como objeto de estudo rodovias rurais de pista dupla em Taiwan e, devido às diferenças operacionais e geométricas de cada pista, procederam à segmentação das rodovias segundo cada sentido de tráfego. Deste modo, o primeiro trabalho teve 498 segmentos por sentido e um total de 996 segmentos e o segundo trabalho, 742 segmentos por sentido e 1484 segmentos no total. É oportuno referir que, nos segmentos estavam distribuídas 47 interseções em desnível e 10 praças de pedágio.

Xie *et al.* (2007) e Li *et al.* (2008) estudaram rodovias de pista simples no Texas, realizando-se a divisão destas em 88 segmentos com extensão variando de 1,11 km a 8,59 km. Os autores, no entanto, não explicitaram os critérios para tal segmentação.

Çodur e Tortum (2015) desenvolveram modelos de previsão de frequência de acidentes para rodovias rurais de pista dupla na Turquia. Os 152 km foram segmentados em 16 trechos com extensão variando entre 4 km e 18,4 km. Os autores referiram que a segmentação ocorreu de forma a garantir que características geométricas e operacionais permanecessem constantes em cada segmento.

Finalmente, Zeng *et al.* (2016a) desenvolveram a modelagem de frequência de acidentes contemplando diversos tipos de rodovias com volume diário médio anual (VDMA) variando de 1164 a 101632 e número de faixas entre 1 e 7. O estudo contou com 211 segmentos rodoviários amplamente distribuídos em Hong Kong, com extensão variando de 0,15 km a 9,07 km.

Na Tabela A.11 estão apresentadas as variáveis independentes (*inputs*) e de saída de cada modelo. Os modelos com o menor número de *inputs* são de Xie *et al.* (2007) e Li *et al.* (2008), ambos com apenas 4 variáveis de entrada. O modelo com mais variáveis explicativas foi o de


Çodur e Tortum (2015), com 18. Junto aos modelos analisados, verifica-se que as variáveis de entrada podem ser enquadradas em três classes: fatores humanos, fatores viário-ambientais e caracterização do acidente.

**Tabela A.11** - Variáveis explicativas e variáveis de saída de cada modelo de frequência de acidentes

Referência	Principais variáveis explicativas	Variáveis de saída
<b>Chang (2005)</b>	13 variáveis: alinhamento horizontal, alinhamento vertical, volume médio diário por faixa, extensão do segmento, inclinação, interseção, trecho militar, porcentagem de caminhões, fator de hora pico, precipitação anual, ano 1998, sentido do trecho, zona de nevoeiro	Número de acidentes/segmento/ano
<b>Chang e Chen (2005)</b>	12 variáveis: alinhamento horizontal, inclinação, volume médio diário por faixa, trecho da via, número de faixas, volume médio diário anual de caminhões, volume médio diário anual de ônibus, volume médio diário anual de tratores/trailers, dias chuvosos, precipitação anual, fator de hora pico, zona de nevoeiro	Número de acidentes/segmento/ano
<b>Xie et al. (2007)</b>	4 variáveis: extensão do segmento, volume de tráfego, largura de pista, largura do acostamento direito	Número de acidentes/segmento
<b>Li et al. (2008)</b>	4 variáveis: extensão do segmento, volume de tráfego, largura de pista, largura do acostamento direito	Número de acidentes/segmento
<b>Çodur e Tortum (2015)</b>	18 variáveis explicativas: ano, rodovia, extensão do segmento, sexo do motorista, fase do dia, condição da superfície da pista, largura do acostamento, largura da divisão central, alinhamento vertical, curvatura horizontal, curvatura vertical, volume de tráfego médio anual, acidentes com veículos pesados, acidentes com veículos leves, acidentes no verão, acidentes no inverno, acidentes no outono, acidentes na primavera	Número de acidentes/segmento
<b>Zeng et al. (2016a)</b>	16 variáveis: volume médio diário anual, extensão do segmento, número de faixas, largura de faixa, limite de velocidade, acesso, saída, número de interseções, inclinação média do segmento, curvatura média do segmento, oportunidade de mudança de faixa (LCO), barreira central, ponto de ônibus, acostamento, estacionamento, precipitação anual	Número de acidentes/segmento/ano

Apresenta-se na Figura A.18 a distribuição dos grupos de variáveis, considerando todos os modelos, em termos do número de variáveis por grupo, quantidade de modelos em que foram empregadas e total de ocorrência destas nos modelos. No eixo das abscissas consta o número de modelos que incorporaram cada grupo de variáveis, ao passo que o eixo das ordenadas corresponde ao número total de variáveis de cada grupo. Por fim, o tamanho das bolhas é dado pelo número total de ocorrências das variáveis de cada grupo.

Há de se destacar a redução de número de variáveis em alguns modelos, decorrentes do agrupamento de *inputs* desagregados que tratavam do mesmo objetivo e tinham o mesmo enquadramento. Çodur e Tortum (2015) por exemplo, utilizou dentre as variáveis de entrada as seguintes: acidentes no verão, acidentes no inverno, acidentes no outono, acidentes na primavera. Estas por se terem o mesmo propósito foram convertidas na variável “estação do ano” na categoria de caracterização do acidente.



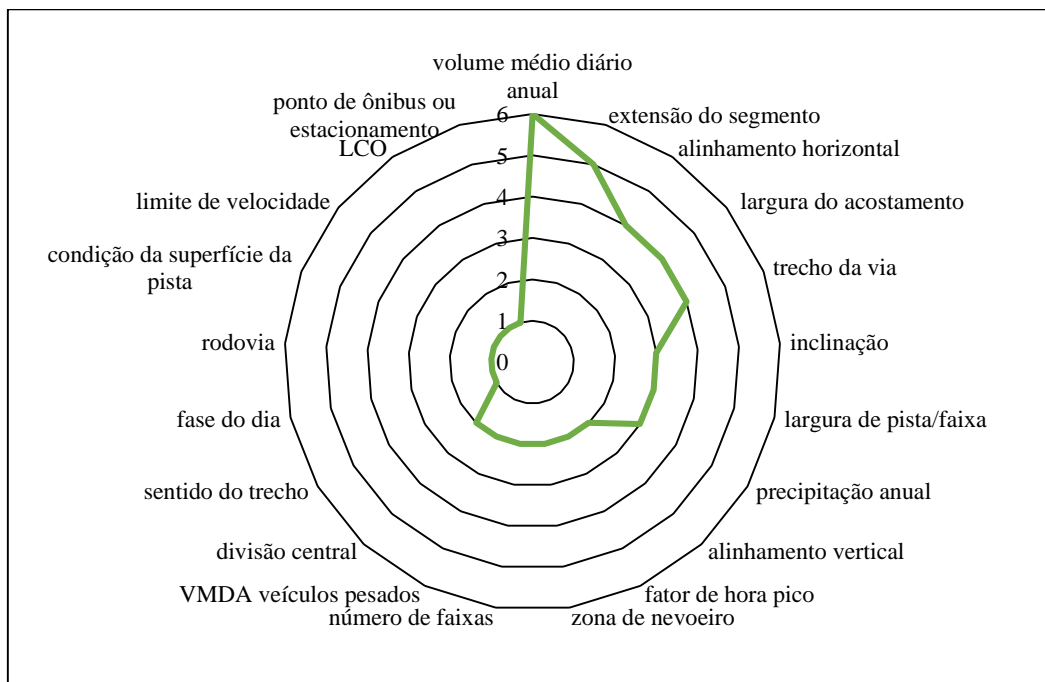
**Figura A. 18-** Distribuição das variáveis explicativas por emprego nos estudos, número de variáveis e número de ocorrências, na modelagem de frequência de acidentes

Denota-se que os fatores viário-ambientais além de terem sido empregados em todos os modelos, possuem quase a totalidade de ocorrência de suas variáveis, correspondendo a mais de 91% do total. Os fatores humanos e variáveis de caracterização do acidente mostraram-se insignificantes com 1,8% e 7,0% de representatividade, respectivamente. É notória, portanto, a imprescindibilidade dos fatores viário-ambientais nos modelos de previsão de frequência de acidentes.

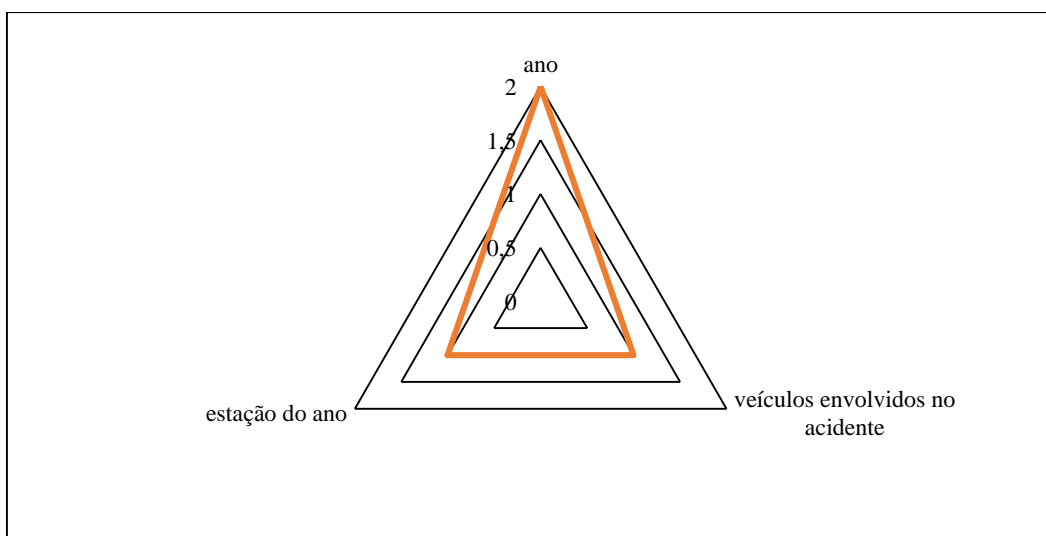
Os *inputs* utilizados em todos os modelos foram agrupados por objetivo e similaridade, resultando em 26 variáveis de entrada. Para compreender melhor a distribuição destas variáveis dentro dos grupos, são apresentadas as Figuras A.19 e A.20.

Os gráficos tipo radar são interessantes por, de forma fácil e visual, possibilitarem a identificação das variáveis de entrada mais utilizadas, segundo cada agrupamento. Nesta abordagem, por obviedade, necessita-se de, pelo menos, 3 variáveis, motivo pelo qual não foi confeccionado o gráfico referente aos fatores humanos.

No caso dos fatores viário-ambientais, destacam-se: volume diário médio anual (VDMA), extensão do segmento, alinhamento horizontal, largura do acostamento e trecho da via. A primeira variável é numérica e pode ter sua unidade expressa por seção ou por faixa, por exemplo. Dada a importância deste indicador, Chang e Chen (2005), além do VDMA geral, utilizaram como variável explicativa o VDMA de veículos pesados (caminhões, ônibus, tratores e *trailers*). Esta é tida como o principal preditor na modelagem de frequência de acidentes, tendo sido incorporada em todos os modelos.



**Figura A.19-** Distribuição dos fatores viário-ambientais na modelagem de frequência de acidentes



**Figura A.20-** Distribuição das variáveis de caracterização do acidente na modelagem de frequência de acidentes

A extensão do segmento foi a segunda variável mais empregada, tendo sido desconsiderada apenas no trabalho de Chang e Chen (2005), haja vista que para a modelagem foram definidos segmentos de extensão constante. Tanto o VDMA quanto a extensão do segmento são variáveis de exposição e, portanto, essenciais para a construção dos modelos.

A variável “alinhamento horizontal” foi utilizada para empregar nos modelos valores numéricos de grau da curva (ou raio) ou curvatura média do segmento, estando presente na maioria dos modelos. Destaca-se que a largura do acostamento ocorreu em 4 dos 6 modelos analisados. Nos modelos de Xie *et al.* (2007), Li *et al.* (2008) e Çodur e Tortum (2015) esta variável era de resposta numérica, enquanto que o modelo de Zeng *et al.* (2016) que tinha como resposta binária a existência ou não de acostamento também foi incluído no mesmo grupo.

Por fim, o trecho da via refere-se a característica geométrica do local do acidente, tendo como opções: interseção, praça de pedágio, acesso ou saída, por exemplo. Ainda vale ressaltar que as cinco principais variáveis são características geométricas ou operacionais das rodovias.


Seguindo no *ranking*, com três ocorrências entre os modelos estão as variáveis: inclinação, largura da pista/faixa e precipitação anual. A inclinação (aclive ou declive) e largura da pista (ou de faixa) são parâmetros de projeto geométrico e podem ter influência sobre a ocorrência de acidentes. A precipitação anual é a primeira medida ambiental a destacar-se. Ela tem sido empregada para avaliar como este tipo de condição climática pode afetar a ocorrência de acidentes.

Ainda neste ensejo, refere-se que 6 variáveis tiveram somente duas ocorrências e ainda, 7 variáveis ocorreram uma única vez. Embora essas variáveis possam ser investigadas e seu potencial para modelagem avaliado, verificou-se que a maioria dos autores não julgou muito relevante seu emprego.

Com relação à caracterização do acidente, apenas a variável “ano” teve relativa significância, com emprego em dois modelos. E o único representante dos fatores humanos foi “Sexo”, com ocorrência única.

Por fim, a Figura A.21 auxilia na análise geral da distribuição das variáveis nos modelos. Devido à irrelevância e melhoria visual gerada, na plotagem do gráfico tipo radar foram excluídas as variáveis com apenas uma ocorrência.

As variáveis de maior destaque foram as mesmas já identificadas entre os fatores viário-ambientais: volume diário médio anual, extensão do segmento, alinhamento horizontal, largura do acostamento, trecho da via, inclinação, largura de pista (ou de faixa) e precipitação anual. Os modelos estão, portanto, baseados nas variáveis relacionadas à via ou ao meio ambiente no qual está inserida.



**Figura A.21-** Distribuição das variáveis de entrada de todos os modelos de frequência de acidentes

O *ranking* permite estabelecer o nível de importância das variáveis para a modelagem, refletida em recorrência de utilização destas no desenvolvimento de modelos de previsão de frequência de acidentes. Entretanto, tais escolhas podem ter sido pautadas em análise preliminar de dados, conveniência ou limitação de dados. De toda forma, essa análise aponta indícios para abordagens em novos trabalhos nesta temática, investigando inclusive o potencial de variáveis ignoradas.

No que se refere aos *outputs* dos modelos, estes se dividiram em: número de acidentes/segmento/ano (CHANG, 2005; CHANG & CHEN, 2005; ZENG *et al.*, 2016) e número de acidentes/segmento (XIE *et al.*, 2007; LI *et al.*, 2008; ÇODUR & TORTUM, 2015).



De forma a completar a sistematização dos modelos de previsão de frequência de acidentes, são apresentados na Tabela A.12 as medidas de desempenho de cada modelo, conjunto de dados para modelagem e *software* utilizado.

**Tabela A.12-** Variáveis explicativas e variáveis de saída de cada modelo de frequência de acidentes

Referência	Medidas de desempenho	Conjunto de dados	Software
<b>Chang (2005)</b>	Acurácia - i) modelo de regressão: 58,3% (treinamento)/60,8% (validação); ii) RNA: 64% (treinamento)/61,4% (validação)	75% dos dados para treinamento e 25% para validação	MATLAB
<b>Chang e Chen (2005)</b>	- Acurácia média i) NB: 52,9% (treinamento)/52,3% (validação); ii) CART: 58,2% (treinamento)/52,6% (validação)	75% dos dados para treinamento e 25% para validação	<i>Salford systems</i>
<b>Xie et al. (2007)</b>	Menor erro: - Binomial negativa i) desvio médio absoluto: 0,96 (treinamento)/0,80 (validação); ii) erro quadrático médio: 2,22 (treinamento)/0,87 (validação); - Redes Neurais com BP: i) desvio médio absoluto: 0,88 (treinamento)/0,84 (validação); ii) erro quadrático médio: 1,17 (treinamento)/0,83 (validação); - Redes neurais bayesianas: i) desvio médio absoluto: 0,84 (treinamento)/0,73 (validação); ii) erro quadrático médio: 1,06 (treinamento)/0,77 (validação)	Três diferentes subconjuntos: 60%, 70% e 80% para treinamento e 40%, 30% e 20% validação. Fez validação cruzada	MATLAB
<b>Li et al. (2008)</b>	Menor erro: - Binomial negativa: i) desvio médio absoluto: 0,96 (treinamento)/0,80 (validação); ii) erro quadrático médio: 1,63 (treinamento)/0,87 (validação); - Máquina de vetores de suporte: i) desvio médio absoluto: 0,79 (treinamento)/0,73 (validação); ii) erro quadrático médio: 0,77 (treinamento)/0,75 (validação); - RNA de Xi et al. (2007): i) desvio médio absoluto: 0,88 (treinamento)/0,84 (validação); ii) erro quadrático médio: 1,17 (treinamento)/0,83 (validação)	Três diferentes subconjuntos: 60%, 70% e 80% para determinação dos parâmetros e 40%, 30% e 20% para avaliação dos erros de predição. Fez validação cruzada por cinco vezes	SAS, MATLAB, LIBSVM
<b>Çodur e Tortum (2015)</b>	- Porcentagem de ajuste dos 5 melhores modelos i) 31-2-1: 0.726160; ii) 31-4-1: 0.691016; iii) 31-7-1: 0.701787; iv) 31-9-1: 0.887323 (melhor modelo); v) 31-10-1: 0.800927. - Desempenho do modelo escolhido i) R <sup>2</sup> : 0,982452; ii) correlação: 0,991186; iii) erro quadrático médio: 4,110521; iv) raiz do erro quadrático médio: 2,027442	70% dos dados para treinamento e 30% para verificação e validação.	Alyuda Neuro Intelligence
<b>Zeng et al. (2016a)</b>	Resultados médios de desvio absoluto médio - i) modelo estatístico: 3,611 (treinamento)/3,702 (validação); ii) RNA: 3,47 (treinamento)/3,573 (validação); iii) RNA otimizada: 3,427 (treinamento)/3,437 (validação)	Validação cruzada por cinco vezes	Stata; MATLAB

Tanto nos modelos de frequência quanto de severidade de acidentes, alguns autores utilizaram validação cruzada (*cross-validation k-fold*). Nesta abordagem, o conjunto de dados inicial é aleatoriamente dividido em *k* subconjuntos com igual número de dados. Em seguida, um de

cada vez, cada subconjunto é utilizado para teste e os demais para treinamento. O segundo passo é repetido  $k$  vezes, finalizando-se então a validação. Por exemplo, Zeng *et al.* (2016a) procederam à validação cruzada por cinco vezes: o conjunto de dados foi dividido em cinco subconjuntos de tamanhos iguais; um por vez, cada subconjunto qualquer foi utilizado para teste enquanto os outros quatro foram empregados para treinamento; o processo foi finalizado mediante a execução de todas as combinações.

#### A.4.8. Modelos de Previsão de Frequência e Severidade de Acidentes

Com a abordagem de modelagem de acidentes por frequência e por severidade, só dois dos modelos foram identificados, dos quais apenas um faz a abordagem de previsão conjunta de frequência e severidade com uso de AM. Ambos os trabalhos foram desenvolvidos por autores com publicação anterior na temática, revelando avanços de pesquisa. O trabalho de Das e Abdel-Aty (2011) é o trabalho mais antigo e foi desenvolvido nos Estados Unidos. Já o estudo de Zeng *et al.* (2016b), desenvolvido na China, é bastante atual. Os escassos resultados por este tipo de abordagem no desenvolvimento de MPA, reforça a justificativa do presente estudo.

Na Tabela A.13 estão apresentadas a quantidade de dados e área de estudo de cada modelo.

**Tabela A.13** - Quantidade de dados e área de estudo de cada modelo de frequência e severidade de acidentes

Referência	Técnica	Dados	Área de estudo	Segmentação
Das e Abdel-Aty (2011)	PG	57155 acidentes do tipo "colisão traseira", entre 2004 e 2006	Vias arteriais urbanas na Flórida	Para modelagem de frequência: divisão em segmentos de extensão igual a 850 m (0,5 milha)
Zeng <i>et al.</i> (2016b)	RNA; MMP	1612 acidentes entre 2002 e 2006	Rodovias de Hong Kong	310 km segmentados em 211 trechos (entre 0,15 km e 9,07 km)

Das e Abdel-Aty (2011), a partir do mesmo conjunto de dados desenvolveram modelos independentes para previsão de frequência e para severidade de acidentes. No caso do modelo dedicado à modelagem de acidentes por severidade (classificação) não foi realizada segmentação, mas procedeu-se à divisão dos dados em 4 *clusters*, de acordo com a extensão das vias, por meio do algoritmo PAM (*Partitioning around the Medoids*), resultando em: *cluster* 1 (1,62 km a 4,65 km), *cluster* 2 (4,66 km a 9,22 km), *cluster* 3 (9,27 km a 16,99 km) e *cluster* 4 (17,13 km a 12,6 km). No caso do modelo de previsão de frequência de acidentes (regressão), procedeu-se divisão de todas as rodovias investigadas em segmento de extensão igual a 850 m

(0,5 milha), diferente do processo de clusterização. Os autores fizeram esta divisão sob justificativa de que, como a ocorrência de um acidente é um evento aleatório, todos os fatores permanecendo constantes, qualquer ponto tem igual probabilidade de ocorrência de acidente. Os modelos desenvolvidos pelos autores consideraram 57155 acidentes do tipo colisão traseira, sendo a modelagem restrita a esta tipologia, que possui o maior quantitativo de registros.

Zeng *et al.* (2016b) utilizaram 1612 dados de acidentes num período de 5 anos, mesma série histórica utilizada por Das e Abdel-Aty (2011). Os 310 km considerados para a análise foram decompostos em 211 segmentos de extensão variável entre 0,15 km e 9,07 km amplamente distribuídos em Hong Kong. Os autores não explicitaram as classes funcionais das rodovias analisadas, mas pela descrição das variáveis explanatórias e discussão dos resultados, depreende-se que foram considerados vários tipos de rodovias. A área de estudo considerada neste trabalho é a mesma utilizada por Zeng *et al.* (2016a).

Na Tabela A.14 estão apresentadas as variáveis independentes (*inputs*) e de saída de cada modelo. Note-se que Das e Abdel-Aty (2011) utilizaram diferentes variáveis de entrada, consoante ao propósito da modelagem. Para a severidade foram utilizados 21 *inputs*, enquanto que para frequência foram adotadas 15 variáveis, todas elas do grupo de fatores viário-ambientais. Dentre todos os *inputs*, 12 são comuns às duas modelagens, a saber: largura da via, limite de velocidade, condição da via, visibilidade, largura de acostamento, condição da superfície da via, fase do dia, condição do pavimento, horário de pico de manhã em dia de semana, horário de pico a tarde em dia de semana, sábado ou domingo à noite, volume diário médio anual.

**Tabela A.14-** Variáveis explicativas e variáveis de saída de cada modelo de frequência e severidade de acidentes

Referência	Principais variáveis explicativas	Variáveis de saída
Das e Abdel-Aty (2011)	<p><b>Severidade (21 variáveis):</b> largura da via, limite de velocidade, condição da via, visibilidade, largura de acostamento, condição da superfície da via, fase do dia, condição do pavimento, horário de pico de manhã em dia de semana, horário de pico a tarde em dia de semana, sábado ou domingo à noite, volume diário médio anual, iluminação, curvatura vertical, presença de estacionamento, tipo de superfície, tipo de acostamento, divisão central, presença de curva, fora do horário de pico, trecho da via (segmento, interseção ou acesso);</p> <p><b>Frequência (15 variáveis):</b> largura da via, limite de velocidade, condição da via, visibilidade, largura de acostamento, condição da superfície da via, fase do dia, condição do pavimento, horário de pico de manhã em dia de semana, horário de pico a tarde em dia de semana, sábado ou domingo à noite, volume diário médio anual, fator de caminhões, rugosidade do pavimento, condições climáticas</p>	<p><b>Severidade (duas classes):</b> i) possível ou não incapacitante lesão, ii) lesão incapacitante e fatalidade;</p> <p><b>Frequência:</b> número de acidentes/segmento.</p>

---

**Zeng et al.  
(2016b)**

16 variáveis: volume diário médio anual, extensão do segmento, número de faixas, largura de faixa, limite de velocidade, acesso, saída, número de interseções, inclinação média do segmento, curvatura média do segmento, oportunidade de mudança de faixa (LCO), barreira central, ponto de ônibus, acostamento, estacionamento, precipitação anual

Duas respostas: Número de acidentes com lesões leves/segmento/ano; Número de acidentes fatais ou com lesões graves/segmento/ano

---

Os modelos investigados empregaram basicamente fatores viário-ambientais. Como tratam-se de modelos com diferentes abordagens não é razoável comparar diretamente as variáveis de entrada dos dois trabalhos, uma vez que para isso seria necessário agrupar as duas modelagens de Das e Abdel-Aty (2011) e tal fato conduziria a um viés. Ainda assim, pôde-se verificar que as variáveis: volume diário médio anual, limite de velocidade e acostamento estiveram presentes em todos os modelos desenvolvidos nos dois trabalhos, podendo estas serem referidas como de destaque.

No rol de variáveis explicativas utilizadas no modelo de frequência de acidentes de Das e Abdel-Aty (2011) duas foram coincidentes às principais elencadas anteriormente na análise da modelagem de frequência de acidentes (item 2.2.4.7), a saber: volume diário médio anual e largura do acostamento. No modelo de previsão de acidentes por severidade, dos mesmos autores, 6 dos *inputs* constavam no rol das principais variáveis da modelagem de acidentes por severidade (item 2.2.4.6), são eles: condições climáticas, iluminação, fase do dia, dia da semana, trecho da via e tipo de acostamento.

Zeng et al. (2016b) tiveram 4 variáveis explicativas coincidentes com as principais da modelagem de frequência de acidentes: volume diário médio anual, extensão do segmento, alinhamento horizontal e trecho da via, esta última também coincidente entre as principais elencadas para modelagem de acidentes por severidade.

Em se tratando de *outputs* dos modelos, Zeng et al. (2016b), considerando a modelagem conjunta frequência-severidade, teve como respostas: número de acidentes com lesões leves/segmento/ano; número de acidentes fatais ou com lesões graves/segmento/ano. Os autores, provavelmente antevendo o problema de queda de desempenho do modelo com problemas de multiclassificação, optaram por utilizar classificação binária para a severidade associada ao número de acidentes.

No trabalho de Das e Abdel-Aty (2011), o modelo de previsão de acidentes por severidade foi abordado como de classificação binária, tendo sido os *outputs*: possível ou não incapacitante lesão e, lesão incapacitante e fatalidade. Já no modelo de frequência de acidentes a saída era número de acidentes/segmento.

De forma a completar a sistematização dos modelos de previsão de frequência e severidade de acidentes, são apresentados na Tabela A.15 as medidas de desempenho de cada modelo, conjunto de dados para modelagem e *software* utilizado.

**Tabela A. 15 - Variáveis explicativas e variáveis de saída de cada modelo de frequência**

Referência	Medidas de desempenho	Conjunto de dados	Software
<b>Das e Abdel-Aty (2011)</b>	- <b>Severidade:</b> Acurácia i) Cluster 1: 91,85%; ii) Cluster 3: 91,48%; iv) Cluster 4: 89,43%; - <b>Frequência:</b> erro quadrático médio i) segmentos: 11,234; ii) interseções sinalizadas: 57,632; iii) acessos: 10,264	70% dos dados para treinamento e 30% para validação	Discipulus™; Mathcad™
<b>Zeng et al. (2016b)</b>	Melhores resultados de desvio absoluto médio - a) lesão leve i) modelo Poisson lognormal: 2,85 (treinamento)/2,82 (validação); ii) RNA: 2,77 (treinamento)/2,76 (validação); iii) RNA otimizada: 2,63 (treinamento)/2,70 (validação); b) fatalidade ou lesão grave i) modelo Poisson lognormal: 1,09 (treinamento)/1,00 (validação); ii) RNA: 1,06 (treinamento)/1,07 (validação); iii) RNA otimizada: 1,02 (treinamento)/1,03 (validação)	Validação cruzada por cinco vezes	WinBUGS; MATLAB

#### A.4.9 Considerações Finais

A análise e sistematização dos trabalhos selecionados concedeu uma visão mais ampla e detalhada de questões importantes para a modelagem da segurança viária com uso de técnicas de AM.

Constatou-se que as principais variáveis explicativas utilizadas nos modelos de previsão de acidentes por severidade estão compreendidas em fatores viário-ambientais, fatores humanos, características do acidente e fatores veiculares, nesta ordem de importância. Ainda assim, Das e Abdel-Aty (2010) e Das e Abdel-Aty (2011) consideraram apenas fatores viário-ambientais neste tipo de modelagem. Nesse contexto, ressalta-se a não necessidade de segmentação das rodovias permitindo o desenvolvimento de modelos baseados em maior quantidade de dados que, em geral, conduz a melhor capacidade de generalização.

No caso da modelagem de frequência de acidentes, fica nítida a predominância dos fatores viário-ambientais como variáveis de entrada dos modelos, sendo as quatro mais importantes pertencentes a este grupo. Verificou-se também, a ocorrência de divisão das rodovias em trechos, podendo ser em segmentos homogêneos (cujas características geométricas e operacionais permanecem inalteradas) ou em segmentos de extensão fixa. Notou-se ainda, que as variáveis de exposição: volume diário médio anual e extensão do segmento (nos casos de segmentos homogêneos), como é de se esperar, estão presentes em todos os modelos de frequência.

A única abordagem, efetivamente conjunta, de previsão de frequência de acidentes por severidade identificada foi de Zeng *et al.* (2016b). Nela, os autores procederam à segmentação das rodovias e utilizaram apenas fatores viário-ambientais como variáveis explicativas.

A única variável que consta no rol das principais da modelagem de acidentes por severidade, está elencada entre as principais dos modelos de frequência de acidentes e está presente no modelo conjunto frequência-severidade de Zeng *et al.* (2016b) é “trecho da via”, com ocorrência em 13 dos 22 modelos analisados. Essa variável pode ter como descrição: reta, curva, interseção, acesso, travessia. Ela se mostrou uma variável importante para caracterização do ambiente rodoviário no caso da modelagem de acidentes por severidade, uma vez que os dados não são associados a trechos com determinadas características, mas também foi utilizada em modelos de frequência de acidentes para considerar os casos de segmentos que incorporem interseções, acessos ou saídas.

A investigação dos modelos permitiu estabelecer o nível de importância das variáveis para a modelagem, refletida em recorrência de utilização destas no desenvolvimento de modelos de previsão de frequência de acidentes. Entretanto, tais escolhas podem ter sido pautadas em análise preliminar de dados, conveniência ou limitação de dados. De todo modo, essa análise norteia abordagens em novos trabalhos nesta temática, podendo se investigar, inclusive, o potencial de variáveis ignoradas ou pouco exploradas.

Dentre os modelos investigados, três foram identificados como resultantes da análise de rodovias rurais de pista dupla: Chang (2005), Chang e Chen (2005) e Çodur e Tortum (2015), todos modelos de frequência de acidentes. Outros modelos incorporaram rodovias de pista

dupla na modelagem, mas associadas a outros tipos de rodovias ou vias urbanas arteriais. Além disso, alguns autores não especificaram para qual tipo de rodovia a modelagem foi desenvolvida. E ainda, a abordagem conjunta frequência-severidade de Zeng *et al.* (2016b) foi desenvolvida para diversos tipos de rodovia. Destarte, a proposta desta tese é útil para preencher a lacuna de modelagem de frequência de acidentes por severidade em rodovias de pista dupla com uso de técnicas de AM. Além de ser uma abordagem inovadora no contexto brasileiro.

Com relação às técnicas de AM empregadas nos diversos modelos, as redes neurais artificiais predominaram e conduziram a resultados satisfatórios. Ademais, em diversos estudos comparativos, os modelos RNA obtiveram melhor desempenho. Destarte, a conjuntura geral indica a adequabilidade desta técnica para a modelagem proposta na tese, observando-se, obviamente, as limitações, desafios e oportunidades de aperfeiçoamento.

## REFERÊNCIAS EXCLUSIVAS DO APÊNDICE

- CAPES (2017) *Portal de Periódicos Capes – Manual*. Disponível em: [https://www.periodicos.capes.gov.br/images/documents/Portal\\_Per%C3%B3dicos\\_CAPES\\_Guia\\_2015-05-25.ppt](https://www.periodicos.capes.gov.br/images/documents/Portal_Per%C3%B3dicos_CAPES_Guia_2015-05-25.ppt). Acesso em: 19/04/2017.
- KITCHENHAM, B.; CHARTERS, S. (2007) *Guidelines for performing systematic literature reviews in software engineering*. Technical Report EBSE-2007-01. School of Computer Science and Mathematics, Keele University, Keele, UK.
- GOOGLE ACADÊMICO (2017) *About Google Scholar*. Disponível em: <https://scholar.google.com/intl/en/scholar/about.htm>. Acesso em: 19/04/2017.

## **APÊNDICE B – MODELAGEM EXPLORATÓRIA DOS DADOS COM TÉCNICAS DE APRENDIZADO DE MÁQUINA**



## B.1. MODELAGEM EXPLORATÓRIA

A modelagem exploratória consistiu basicamente na investigação da forma mais eficiente de regularização das variáveis e modelagem inicial com três regressores.

### B.1.1. Regularização das Variáveis

O passo inicial da modelagem foi definir o procedimento de regularização dos dados, transformando todas as variáveis para a mesma ordem de grandeza. Para tanto, foram realizados testes de:

- Padronização: neste caso, os diferentes atributos poderão abranger intervalos diferentes, mas deverão possuir os mesmos valores para alguma medida de posição e de espalhamento/variação. Tipicamente a média e o desvio-padrão são as medidas adotadas, de modo que cada atributo terá média nula e desvio-padrão unitário. A padronização de um atributo  $j$  para um objeto  $x_i$  é dado por:

$$x_{ij,nov} = \frac{x_{ij} - \bar{x}_j}{s_j} \quad (\text{B.1})$$

Em que:

$x_{ij,nov}$  – valor reescalado do atributo  $j$  do objeto  $x_i$  ;

$x_{ij}$  – valor original do atributo  $j$  do objeto  $x_i$  ;

$\bar{x}_j$  – média populacional do atributo  $j$ ;

$s_j$  – desvio padrão do atributo  $j$ .

- Padronização e transformação logarítmica: além de proceder à padronização, como descrito acima, fez-se a transformação logarítmica da variável *VDMA* (volume de tráfego).
- Normalização: essa abordagem redefine, através de um valor mínimo e um valor máximo, um novo intervalo onde os valores de um atributo estarão contidos. A normalização de um atributo  $j$  para um objeto  $x_i$  pode ser calculado da seguinte forma:

$$x_{ij,nov} = \frac{x_{ij} - \min_j}{\max_j - \min_j} \quad (\text{B.2})$$

Em que:

$\min_j$  e  $\max_j$  são, nessa ordem, os valores mínimo e máximo do atributo  $j$  para o conjunto de dados considerado.

Padronização e transformação logarítmica: além de efetuar a padronização, como descrito acima, fez-se a transformação logarítmica da variável *VDMA* (volume de tráfego).

- Normalização e transformação logarítmica: além de proceder à normalização, também fez-se a transformação logarítmica da variável *VDMA* (volume de tráfego).

Inicialmente fez-se a regularização dos dados, testando a padronização, normalização e mudança de escala de variáveis. Pelos testes, a convergência otimizada e erros minimizados foram auferidos mediante padronização dos dados, abordagem adotada na modelagem.

Procedeu-se à regressão linear dos pontos correspondentes aos erros médios MSE para cada extensão de segmento, para cada pista, em cada período de tempo e para cada uma das variáveis-resposta, em cada uma das abordagens de regularização dos dados (padronização, normalização e transformação logarítmica). A alternativa com maior  $R^2$  e menor coeficiente angular da reta, e conseqüentemente menores valores médios de erro, foi escolhida.

### **B.1.2. Testes Exploratórios com Regressores**

Embora se tenha constatado maior aderência das RNA ao propósito da pesquisa, explorou-se inicialmente, para fins confirmatórios, outras técnicas de regressão, a saber: *Random Forest* e *kNN*.

*Random Forest* (RF), ou floresta aleatória, é uma técnica *ensemble* baseada em CART (referidas no Capítulo 2). Conforme Dietterich (2000), *ensemble* é um conjunto de modelos que combinados produzem a predição de resposta para um novo caso. Formalmente é um classificador consistindo de uma coleção de árvores  $\{h_k(x, \Theta_k), k = 1, 2, \dots, N\}$ , em que  $\Theta_k$  são

vetores independentes e aleatoriamente distribuídos e cada árvore vota na classe mais popular para a entrada  $x$  (BREIMAN, 2001). As amostras são obtidas a partir do conjunto original de dados e, seguidamente, as árvores de classificação e/ou regressão são geradas com seleção aleatória das características (atributos) de cada amostra. Por fim, as árvores são combinadas para emitir a predição do conjunto. Quando classificador, a classe resultante é proveniente da maioria dos votos; nos regressores, o resultado é a média dos resultados de todas as árvores.

O algoritmo *k-Nearest Neighbors* é um dos mais clássicos e utilizados em Mineração de Dados. O método baseia-se na proximidade de seus vizinhos em um espaço amostral e objetiva formar uma generalização, com base no conjunto de treinamento, maximizando a acurácia da classificação de novos dados (Gao & Gao, 2010). No caso de regressão, considere  $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$  o conjunto de treinamento com métricas de distância  $d$ , em que  $x_i = (x_{i1}, x_{i2}, \dots, x_{im})$  é a instância denotada com  $m$  atributos para sua saída  $y_i$  e  $N$  é o número de instâncias. Diante de uma instância de teste  $x$ , calcula-se a distância  $d_i$  entre  $x$  e cada instância  $x_i$  em  $T$ , e classifica a distância  $d_i$  pelo seu valor. Se  $d_i$  for classificada no  $i$ -ésimo lugar, a distância da instância correspondente será chamada de  $i$ -ésimo vizinho mais próximo  $NN_i(x)$ , e sua saída será  $y_i(x)$ . Finalmente, a previsão de saída  $\hat{y}$  de  $x$  é a média das saídas de seus  $k$  vizinhos mais próximos na regressão,  $\hat{y} = \frac{1}{k} \sum_{i=1}^k y_i(x)$  (KUDRASZOW & VIEU, 2013; SONG *et al.*, 2017).

Ambas as técnicas permitem a previsão de mais de uma saída simultaneamente, no entanto, desconsiderando a correlação existente entre elas. Os resultados advindos do emprego de RNA, *kNN* e *Random Forest* foram comparados em termos de Erro relativo (ER), o que, juntamente com os achados da revisão sistemática, confirmaram maior adequação das redes neurais ao tipo de modelagem.

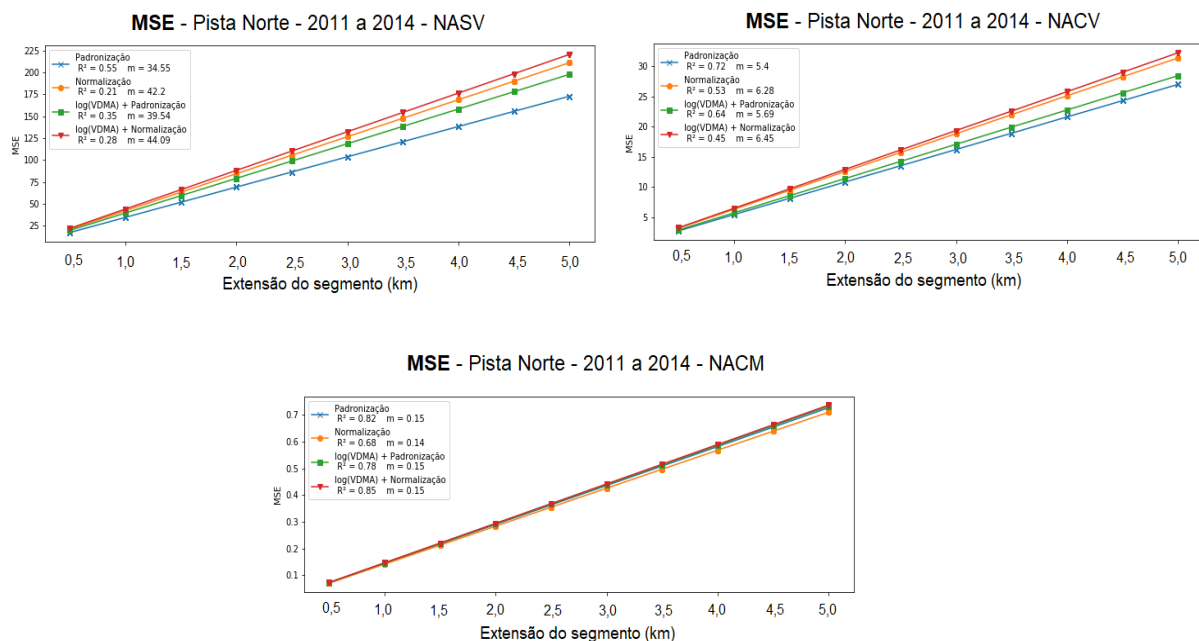
## B.2. RESULTADOS DA MODELAGEM EXPLORATÓRIA

Na sequência são apresentados os resultados e discussões acerca da modelagem exploratória.

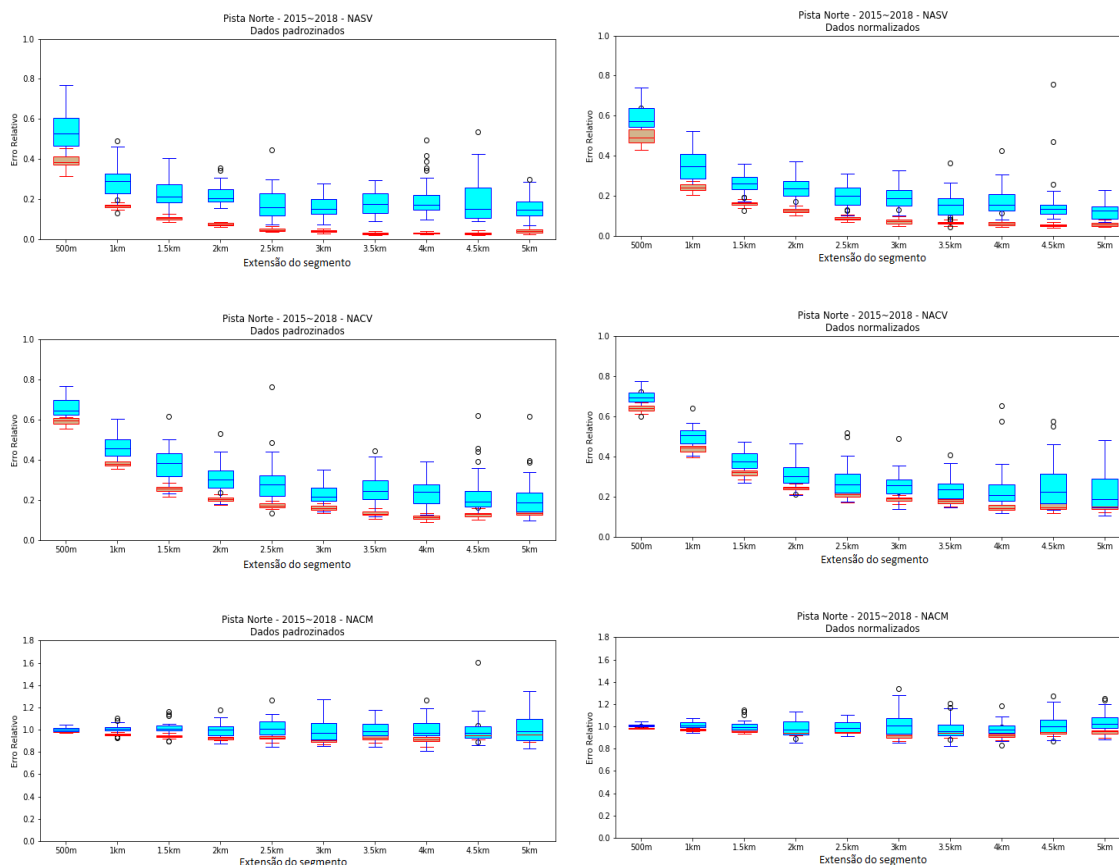
### B.2.1. Regularização dos Dados

Os testes preliminares, assim como era esperado, deram conta de que a escala original dos dados não seria adequada à modelagem. Fez-se, portanto, a regularização dos dados, testando a padronização, normalização e mudança de escala de variáveis, antes do emprego das redes neurais. Procedeu-se à regressão linear dos pontos correspondentes aos erros médios MSE para cada extensão de segmento, para cada pista, em cada período de tempo e para cada uma das variáveis-resposta, em cada uma das abordagens de regularização dos dados (padronização, normalização e transformação logarítmica).

Os resultados de erro relativo (ER) e MSE foram avaliados. A alternativa com maior  $R^2$  e menor coeficiente angular da reta, e conseqüentemente menores valores médios de MSE, foi escolhida. A título de exemplo, apresenta-se na Figura B.1 o resultado da Pista Norte no período 2011-2014 para cada uma das variáveis-resposta. Nota-se, portanto, que o melhor ajuste ocorre aquando da padronização dos dados originais. Comportamento similar foi verificado em outros casos, como evidenciado na Figura B.2 em que são comparados os desempenhos de cada modelo da Pista Norte no período 2015-2018, segundo ER. Tais constatações embasaram o emprego da padronização no processo de modelagem com técnicas de AM.



**Figura B. 1**– Desempenho das diferentes alternativas de regularização dos dados para as respostas NASV, NACV e NACM, para Pista Norte, período 2011-2014.



**Figura B. 2** - Desempenho das diferentes alternativas de regularização dos dados para as respostas NASV, NACV e NACM

### B.2.2. Testes Exploratórios com Regressores

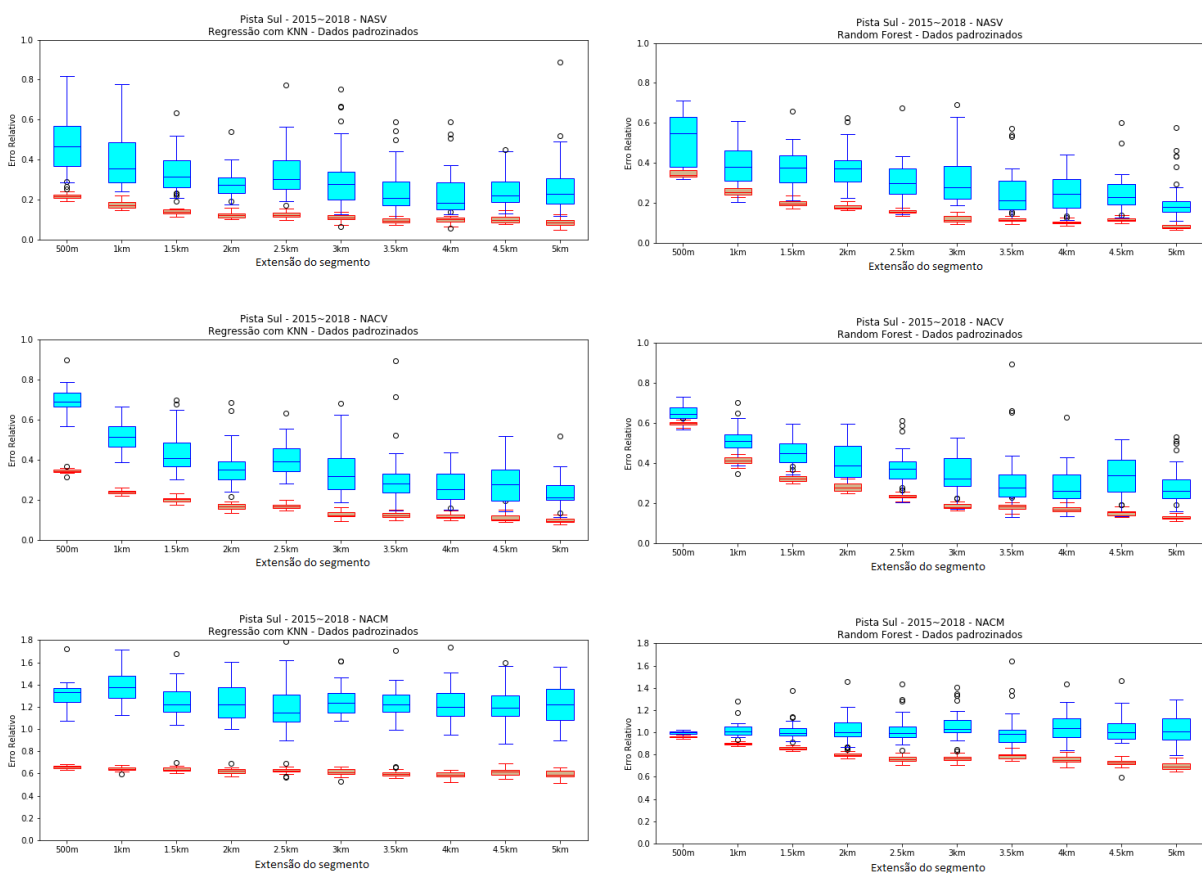
Além do uso de redes neurais artificiais (RNA), tida como mais adequada ao objetivo da pesquisa, explorou-se, apenas para fins confirmatórios, duas outras técnicas de regressão: *Random Forest* e *kNN*.

Para RNA o procedimento foi iniciado com uma rede de arquitetura simples, contendo apenas uma camada oculta com 25 neurônios. Em seguida, mediante diversas experimentações, verificou-se que o aumento de uma camada oculta a cada nova extensão de segmento otimizava o processo de convergência e os resultados dos modelos, pelo que adotou-se 1 camada oculta para segmentos de extensão 500 m, 2 camadas ocultas para segmentos de extensão 1 km, e assim até a arquitetura com 10 camadas para segmentos de extensão 5 km. O aumento da complexidade da rede conforme os segmentos tornam-se mais extensos foi necessária pois, com o aumento da extensão dos segmentos, diminuía o número de observações. Dessa forma, a rede precisa de mais conexões para obter boa capacidade de generalização com número reduzido de dados de entrada.

Os resultados dos testes exploratórios, em termos de ER, estão apresentados nas Figuras 5.3 e 5.4. Por questão de espaço, são apresentados os resultados apenas da Pista Sul no período 2015-2018, no entanto, comportamento análogo é verificado nos demais casos. Os *box plot* azuis são relativos aos resultados de treinamento e os vermelhos aos de teste.

De acordo com a Figura B.3, a regressão com *kNN* apresenta patamares reduzidos de ER desde o segmento de 500 m, tendo pequenos incrementos de desempenho ao longo dos segmentos mais extensos, culminando no menor ER de treinamento no segmento de 5 km, tanto para *NASV* como *NACV*. No caso de *Random Forest*, os erros iniciais, especialmente do segmento de 500 m, são mais elevados e têm queda acentuada até o segmento de 3 km, quando nota-se tendência de estabilização dos valores de ER.

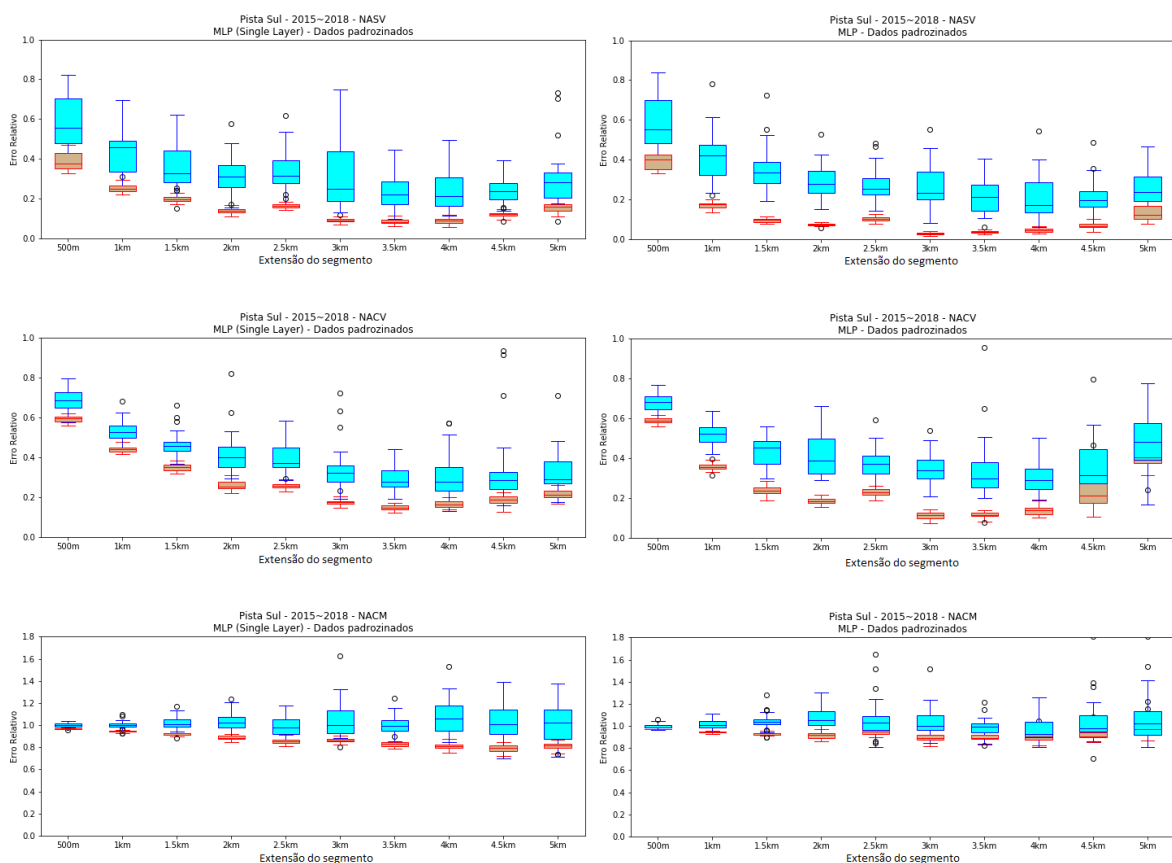
Quanto ao *NACM*, os resultados oriundos do *kNN* são sensivelmente melhores que os resultantes da outra abordagem. Isso, no entanto, não evidencia a adequação da técnica para resolução desse problema. Nota-se evidente discrepância entre os valores de ER para o treinamento e para o teste.



**Figura B. 3** – Desempenho dos modelos para PS, período 2015-2018, com uso de *kNN* regressor e *Random Forest*

Os resultados do treinamento ajustaram-se em excesso aos dados apresentados, mas não tiveram capacidade de generalização quando foram apresentados dados de validação, configurando *overfitting*. E, quando comparados os valores de ER para o conjunto de teste, os valores medianos dos modelos *kNN* são notavelmente superiores aos dos modelos *Random Forest*. Embora em menores proporções, nota-se tendência de sobreajuste dos dados no modelo *kNN* também para *NASV* e *NACV*, quando comparado ao modelo *Random Forest*; motivo pelo qual é possível, numa análise global, afirmar que essa última técnica conduz a melhores resultados que a primeira.

Do lado esquerdo da Figura B.4 estão apresentados os resultados de modelos com uso de redes simples com apenas uma camada oculta (MPL-1) enquanto que, do lado direito estão os resultados oriundos da utilização de diferentes números de camadas (MPL-n), como explicado anteriormente.



**Figura B. 4** – Desempenho dos modelos para PS, período 2015-2018, com uso de *kNN* regressor e *Random Forest*

Nota-se similaridade de desempenho em ambas as abordagens, porém, vê-se melhor ajuste dos modelos a partir do segmento de 1 km e tendo como ER mínimo os modelos de treinamento

para segmentos de 3 km, em todas as saídas (*NASV*, *NACV* e *NACM*). Tal verificação confirma os esforços para conferir maior robustez à rede neural de forma que consiga manter a capacidade de generalização mesmo com a redução do número de observações.

Ainda quanto aos modelos de RNA, percebe-se a curva de decaimento do erro a partir do segmento de 500 m até atingir o valor mínimo e retomar, mesmo que ligeiramente, o aumento do ER. Para a rede MLP-1 o segmento com valores mínimos de erro é o de 3,5 km enquanto para MLP-n é o segmento de 3 km. É perceptível também a concordância geral de comportamento dos erros tanto no conjunto de treinamento quanto no de teste.

Diante disso, pelos patamares menores de erros e coerência de resultados entre treinamento e teste e ainda, a não consideração da correlação existente entre as variáveis de saída na previsão simultânea de resposta mediante uso de *kNN regressor* e *Random Forest*, nota-se maior adequação das RNA aos propósitos da modelagem. Além disso, dada a melhoria de desempenho para segmentos mais extensos, a abordagem utilizando redes com diferentes números de camadas ocultas será aplicada.

Ainda assim, refere-se que o desempenho dos modelos em termos de *NACM* tem mostrado inconsistência em todas as abordagens, sendo alvo de estratégias específicas, que são apresentadas ainda neste capítulo. E também, ainda que não configure *overfitting*, a diferença entre o ER no conjunto de treinamento e teste foi alvo de aprimoramento.

## **REFERÊNCIAS EXCLUSIVAS DO APÊNDICE**

- BREIMAN, L. (2001) Random forests. *Machine Learning* v. 45(1), p. 5-32.
- GAO Y. & GAO, F. (2010) Edited AdaBoost by weighted KNN. *Neurocomputing*, v. 73(16), p. 3079-3088.



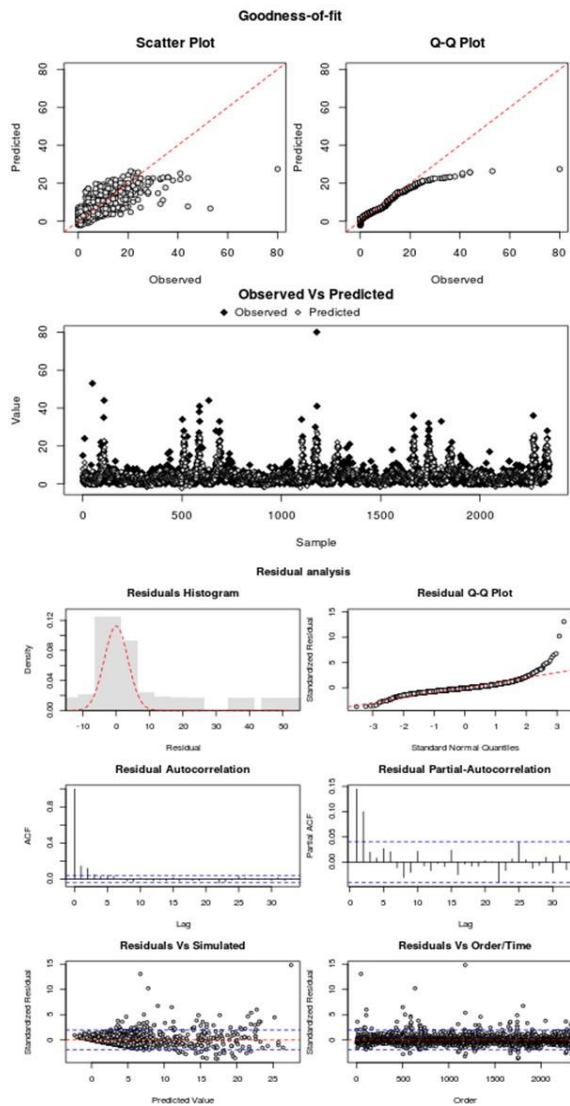
**APÊNDICE C – ESTATÍSTICA DESCRITIVA, GRÁFICOS DE  
QUALIDADE DE AJUSTE E ANÁLISE DE RESÍDUOS  
COMPLEMENTARES**

**Tabela C. 1 – Estatística descritiva dos segmento de 3,5 km da Pista Norte e 4 km da Pista Sul**

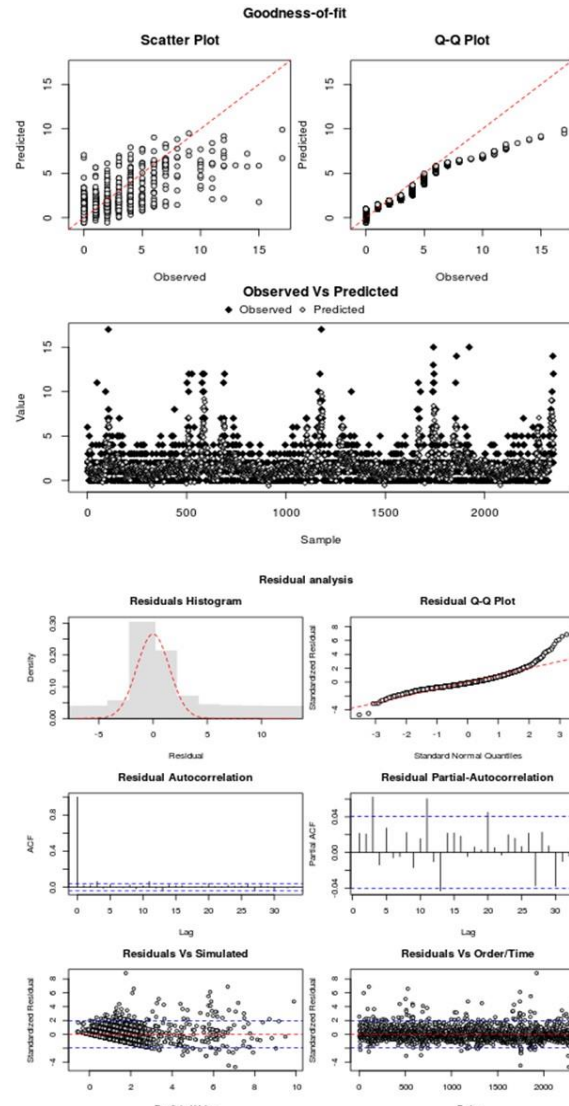
	PN_3,5km_2011-2014 (400 observações)				PN_3,5km_2015-2018 (400 observações)				PS_4km_2011-2014 (348 observações)				PS_4km_2015-2018 (348 observações)			
<b>Variáveis resposta</b>																
Variável	Mín	Máx	Média	DP	Mín	Máx	Média	DP	Mín	Máx	Média	DP	Mín	Máx	Média	DP
<i>NASV</i>	1	248	31,37	30,22	1	136	23,14	19,99	3	327	31,53	33,33	3	154	23,51	20,13
<i>NACV</i>	0	66	11,12	9,79	0	58	9,19	8,11	1	73	12,26	11,09	0	52	10,07	8,96
<i>NACM</i>	0	3	0,41	0,70	0	3	0,28	0,53	0	3	0,43	0,69	0	4	0,27	0,57
<b>Variáveis explanatórias numéricas</b>																
Variável	Mín	Máx	Média	DP	Mín	Máx	Média	DP	Mín	Máx	Média	DP	Mín	Máx	Média	DP
<i>VDMA</i>	11591,92	66758,60	22414,94	10142,11	11812,79	67189,70	22561,58	10896,68	11682,58	81818,62	23292,04	11665,93	11812,33	76104,18	23476,17	12688,98
<i>IMA</i>	0,00	4,17	1,42	0,94	0,00	4,17	1,42	0,94	0,22	5,50	1,66	1,07	0,22	5,50	1,66	1,07
<i>IMD</i>	0,16	5,47	1,65	1,12	0,16	5,47	1,65	1,12	0,00	4,23	1,50	0,93	0,00	4,23	1,50	0,93
<i>L_acost</i>	0,06	3,49	1,67	0,65	0,06	3,49	1,67	0,65	0,46	3,20	1,62	0,52	0,46	3,20	1,62	0,52
<i>L_cant</i>	0,00	20,00	2,24	3,78	0,00	20,00	2,24	3,78	0,00	20,00	2,10	3,49	0,00	20,00	2,10	3,49
<i>N_faixas</i>	2,00	3,00	2,05	0,22	2,00	3,00	2,05	0,22	2,00	3,00	2,02	0,15	2,00	3,00	2,02	0,15
<i>N_aceessos</i>	0,00	6,00	1,98	1,30	0,00	6,00	1,98	1,30	0,00	7,00	2,43	1,59	0,00	7,00	2,43	1,59
<i>N_saídas</i>	0,00	6,00	2,08	1,28	0,00	6,00	2,08	1,28	0,00	9,00	2,57	1,70	0,00	9,00	2,57	1,70
<i>PCC</i>	0,00	0,66	0,25	0,18	0,00	0,66	0,25	0,18	0,00	0,60	0,25	0,18	0,00	0,60	0,25	0,18
<i>PCR</i>	0,34	1,00	0,75	0,18	0,34	1,00	0,75	0,18	0,40	1,00	0,75	0,18	0,40	1,00	0,75	0,18
<i>IRH</i>	0,00	0,02	0,00	0,00	0,00	0,02	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,01	0,00	0,00
<i>V_max</i>	40,00	110,00	98,80	14,80	40,00	110,00	98,80	14,81	80,00	110,00	100,69	10,39	80,00	110,00	100,69	10,39
<i>P_ilum</i>	0,00	1,00	0,03	0,14	0,00	1,00	0,03	0,14	0,00	1,00	0,03	0,12	0,00	1,00	0,03	0,12
<i>CEV</i>	0,00	3,00	0,28	0,51	0,00	3,00	0,28	0,51	0,00	2,00	0,24	0,45	0,00	2,00	0,24	0,45
<i>QI</i>	24,54	33,08	28,60	2,83	22,65	30,46	26,74	2,02	24,62	30,76	27,86	2,23	24,01	29,42	26,44	1,60
<b>Variáveis explanatórias categóricas</b>																
Variável	Valor	Frequência	Porcentagem	Frequência	Porcentagem	Frequência	Porcentagem	Frequência	Porcentagem							
<i>Div_pista</i>	Barreira ( <i>Div_pista_B</i> )	260	65,00%	195	65,00%	228	65,50%	171	65,50%							
	Canteiro ( <i>Div_pista_C</i> )	140	35,00%	105	35,00%	120	34,50%	90	34,50%							
<i>Uso_solo</i>	Urbano ( <i>Uso_solo_U</i> )	320	80,00%	240	80,00%	268	77,00%	201	77,00%							
	Rural ( <i>Uso_solo_R</i> )	80	20,00%	60	20,00%	80	23,00%	60	23,00%							

**Quadro C. 1 - Descrição dos elementos gráficos complementares de avaliação dos modelos**

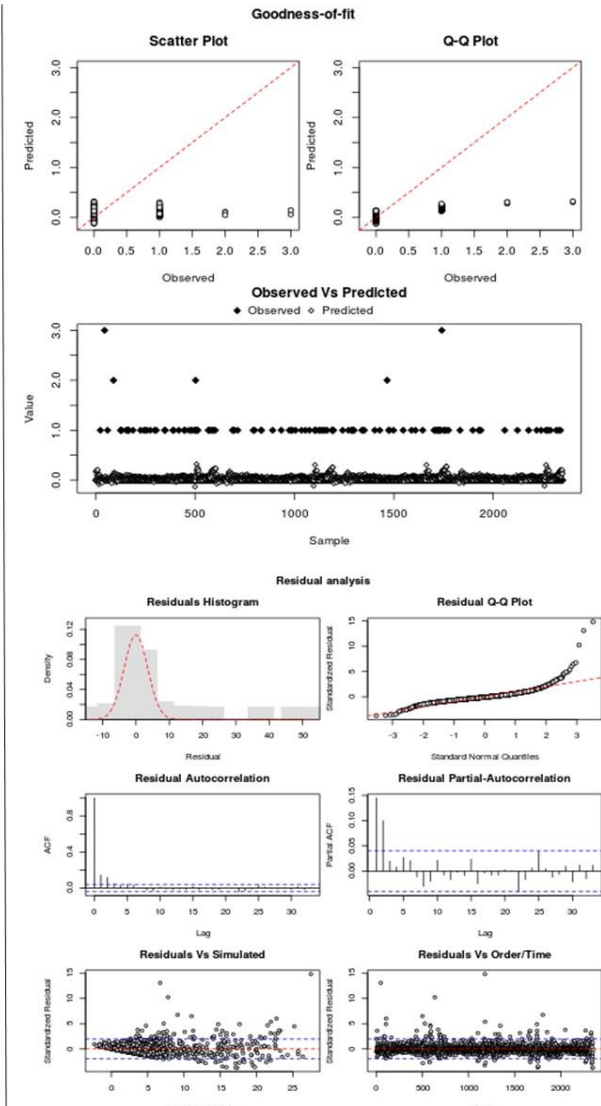
<b>Análise gráfica</b>	
<b>Gráfico</b>	<b>Descrição</b>
<i>Scatter Plot</i>	Gráfico de dispersão de dados observados <i>versus</i> previstos – Método simples que permite avaliar graficamente quão bem o modelo se ajusta ao conjunto de dados apresentado. Um modelo preciso e imparcial deve apresentar os pontos ao longo da linha 1:1, com dispersão sobre essa linha representando a discrepância entre as observações e o modelo. A inspeção visual é útil para verificação de padrões de sub ou superestimação de valores, quando se notar divergência sistemática da linha de 45°. O desempenho do modelo pode ser classificado como de baixa, média ou alta magnitude (BENNETT <i>et al.</i> , 2013).
<i>Observed vs Predicted</i>	Gráfico de dados observados e previstos - Se os dados foram obtidos em uma sequência de tempo ou espaço, um gráfico dos dados observados e ajustados em relação à ordem dos dados (espacial e/ou temporal) é uma ferramenta gráfica interessante para visualizar o desempenho do modelo, fornecendo informações sobre qualquer deficiência do modelo, como erros em algum tempo ou local específico, desempenho não homogêneo e falha de correspondência em valores discrepantes (CROUT <i>et al.</i> , 2008). Independente da ordem espacial e/ou temporal, esse gráfico pode fornecer informações sobre a precisão do modelo e como ele se comporta em relação aos dados.
<i>Residuals histogram</i>	Histograma de resíduos - Um histograma dos resíduos permite que a normalidade dos resíduos seja verificada graficamente, fornecendo uma imagem clara da forma da distribuição residual, sendo possível notar aspectos da forma, escala, localização e simetria (ou falta dela) dos resíduos.
<i>Residual Partial-Autocorrelation Function (PACF) Plot</i>	Gráfico de autocorrelação parcial de resíduos – O gráfico PACF não é necessário para validação, sendo útil para auxiliar na escolha de um modelo de séries temporais (identificação da ordem do modelo) caso o gráfico ACF indique correlação residual relevante.
<i>Residual vs Simulated</i>	Gráfico de resíduos padronizados <i>versus</i> valores previstos – Este gráfico apresenta valores de saída do modelo no eixo <i>x</i> e resíduos padronizados no eixo <i>y</i> , sendo particularmente útil para identificar variações não constantes nos resíduos. Idealmente, os resíduos não devem apresentar padrão, estando dispersos mais ou menos em uma faixa horizontal, simétrica em torno de zero (se os resíduos são normalmente distribuídos, 95% dos resíduos padronizados devem ficar entre $\pm 1,96$ ) (BATES E WATTS, 1988). Esse gráfico também pode ser útil para identificar valores discrepantes ( <i>outliers</i> ) nos dados, que podem ser sinalizados por resíduos particularmente grandes.
<i>Residuals vs Order/Time</i>	Gráfico de resíduos padronizados na ordem dos dados - Se a ordem espacial e/ou temporal dos dados for conhecida, esse gráfico pode ser útil para identificar a correlação serial nos resíduos, o que sugere um comportamento determinístico não modelado nos dados. Idealmente não deve haver um padrão visível nesse gráfico residual e os resíduos devem estar aleatoriamente aproximadamente dentro de uma faixa horizontal. Se a estrutura não aleatória for evidente neste gráfico, a suposição de resíduos independentes e o uso da função objetivo SSE para calibração podem não ser apropriados.



(a) NASV

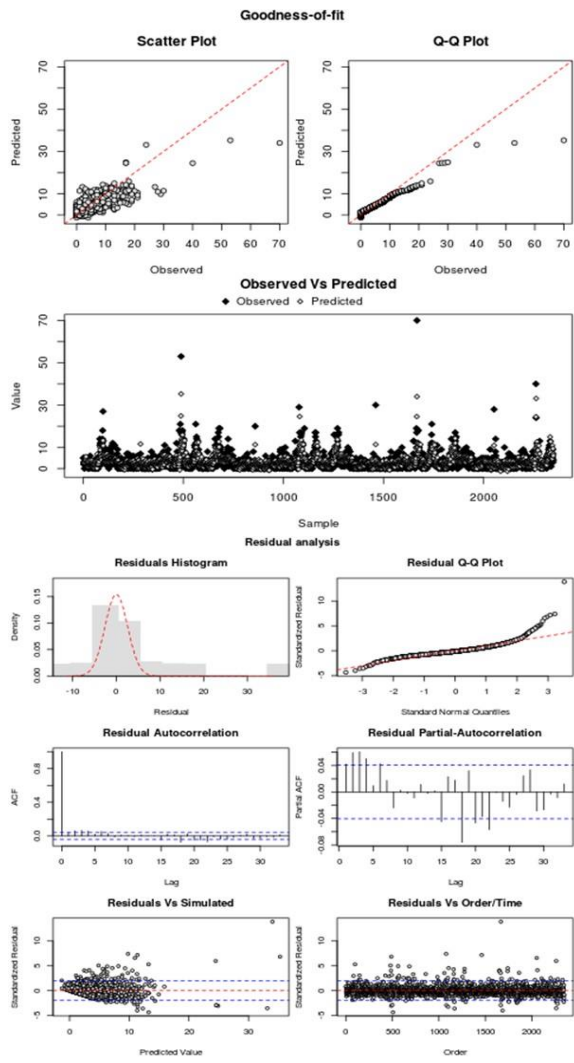


(b) NACV

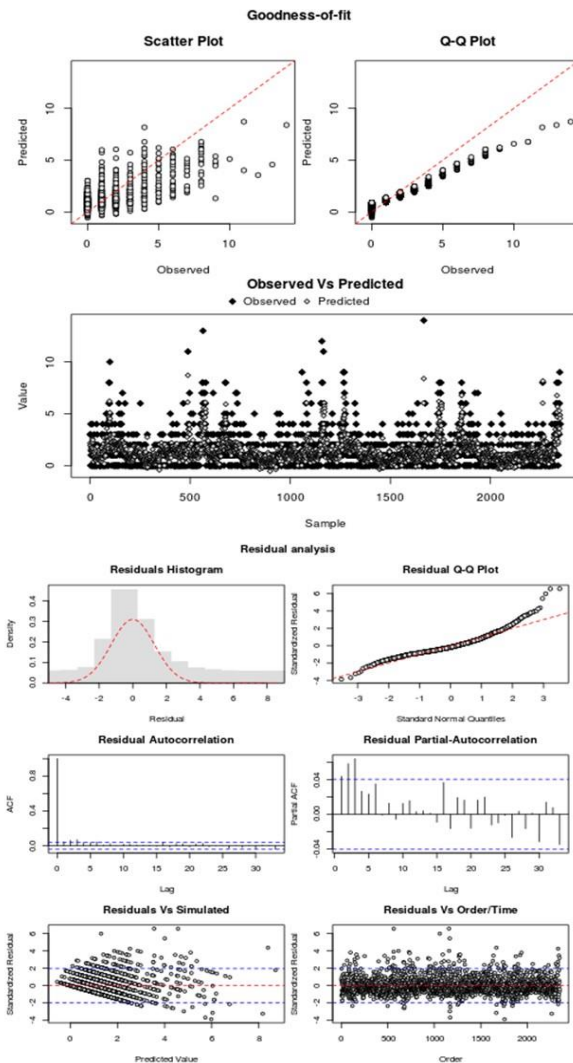


(c) NACM

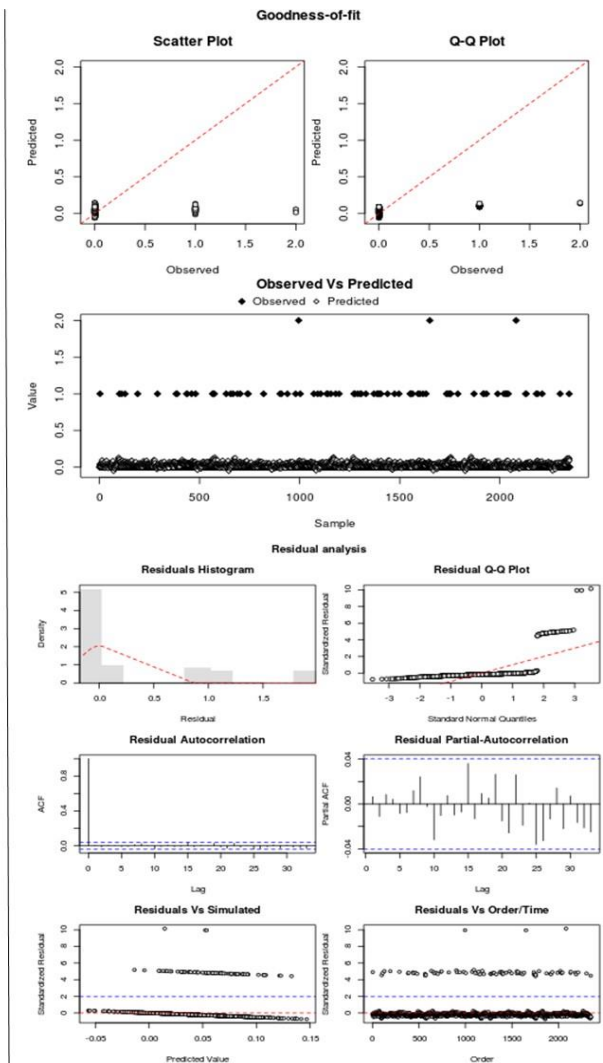
Figura C. 1 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_500m\_2011\_2014 (RNA)



(a) NASV

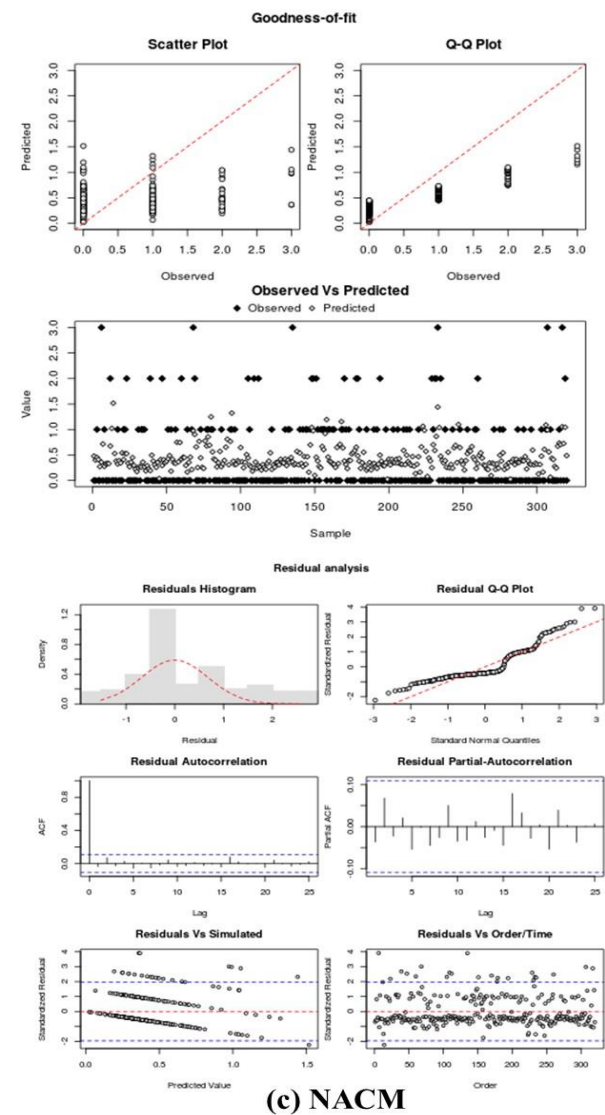
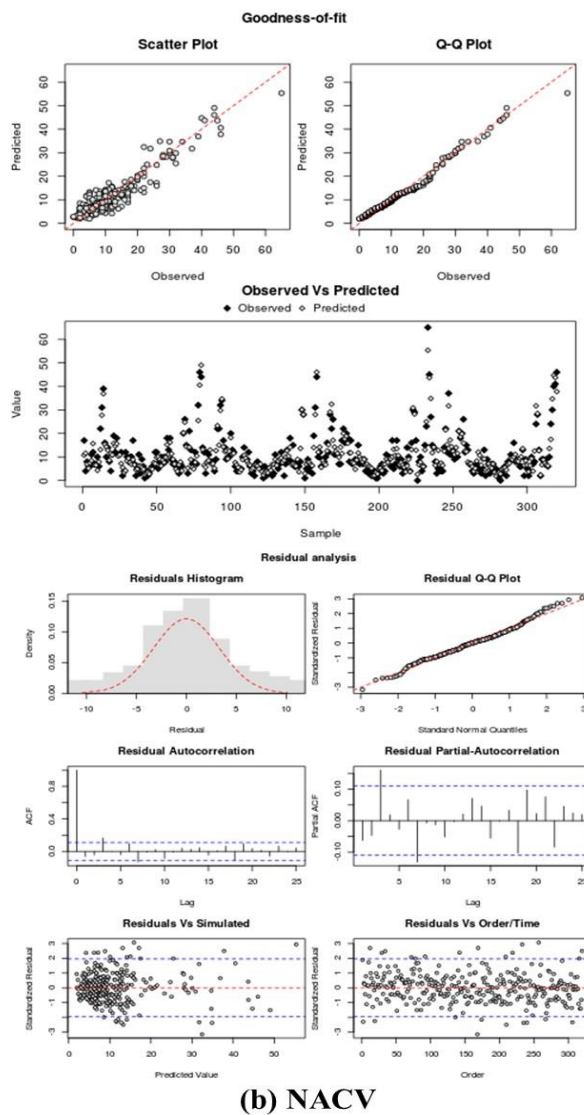
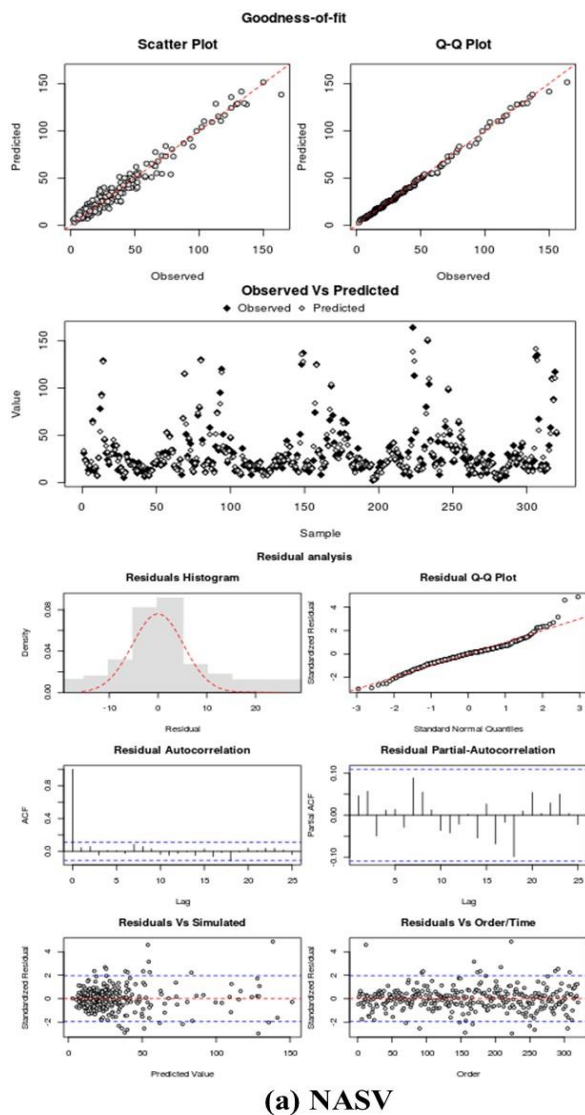


(b) NACV

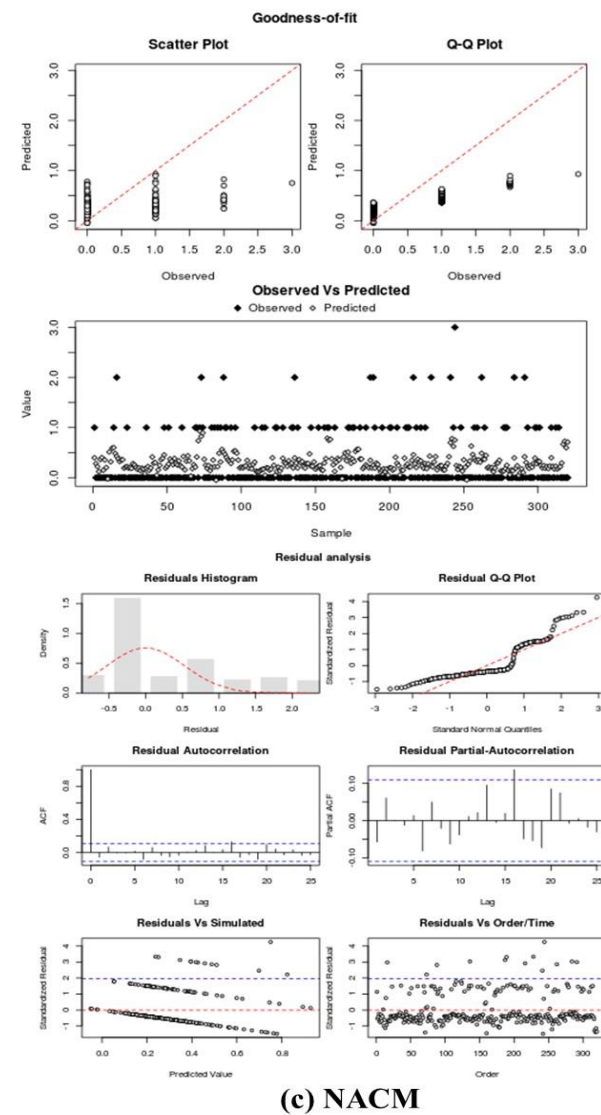
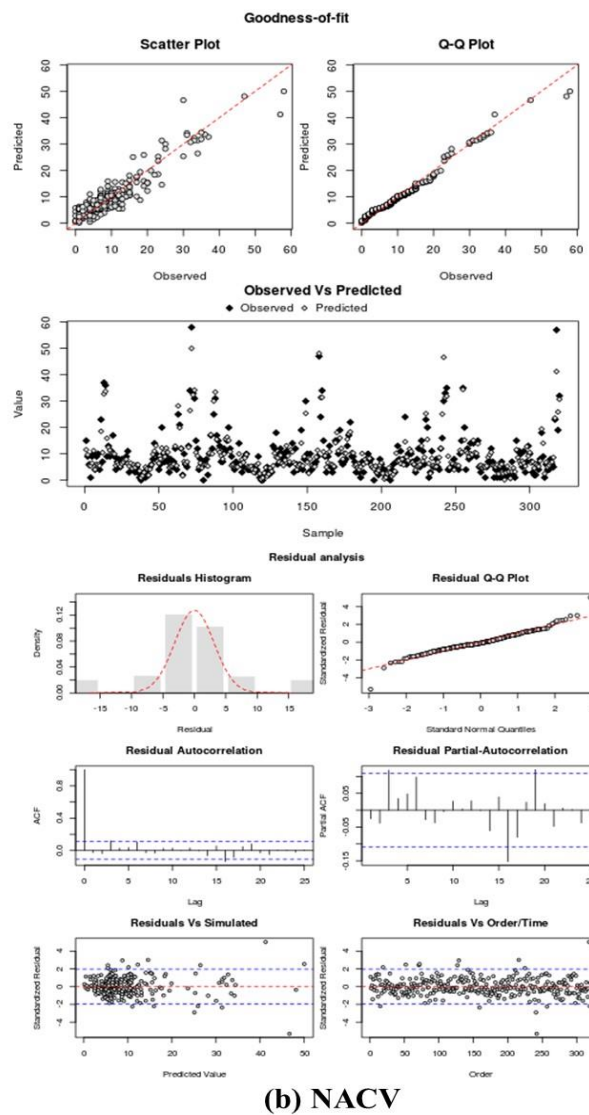
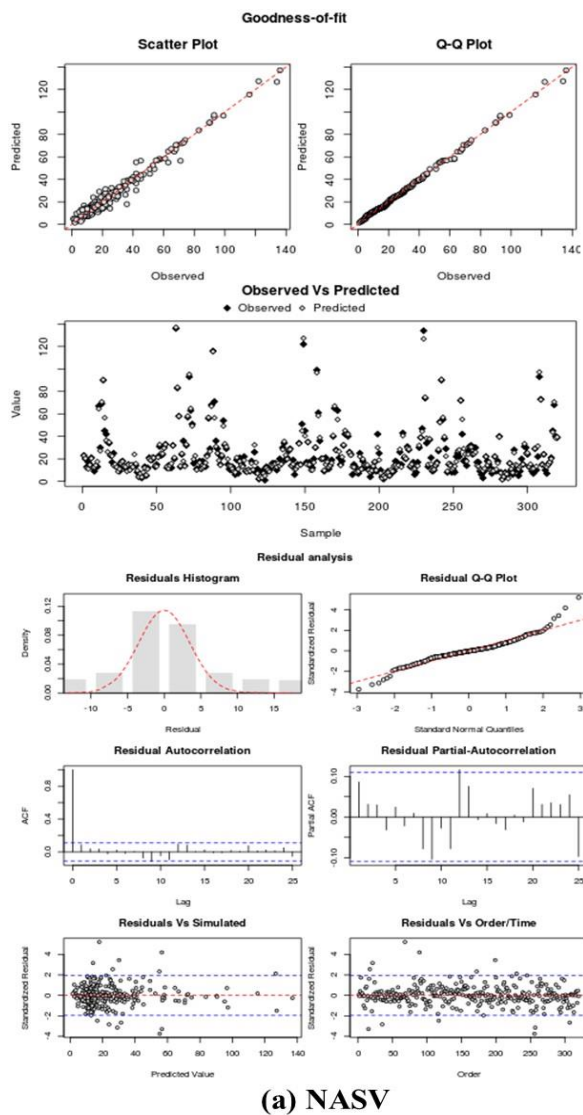


(c) NACM

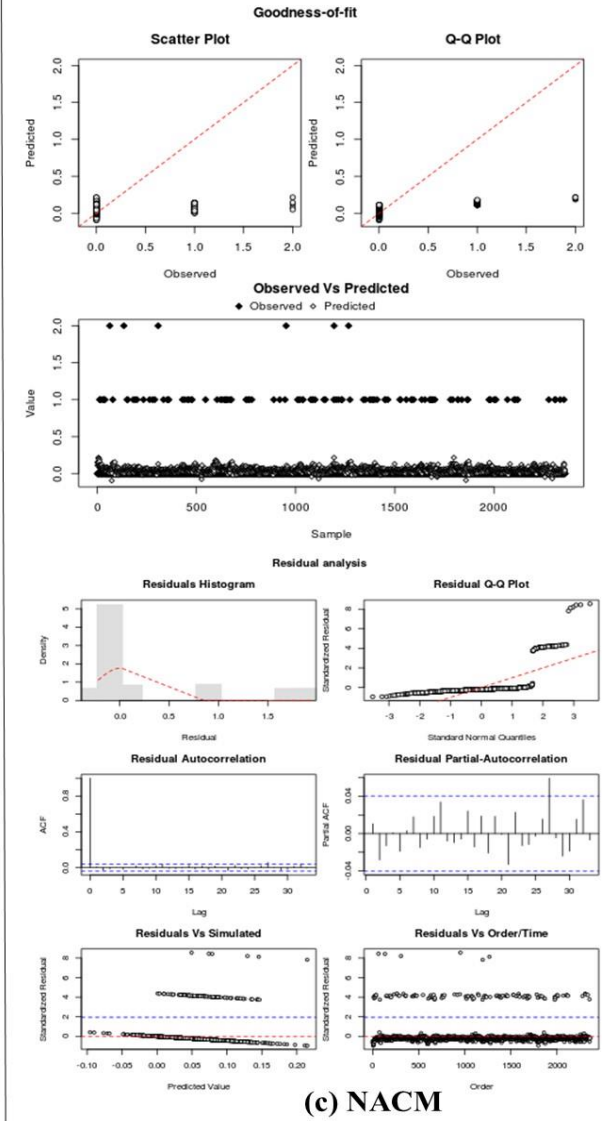
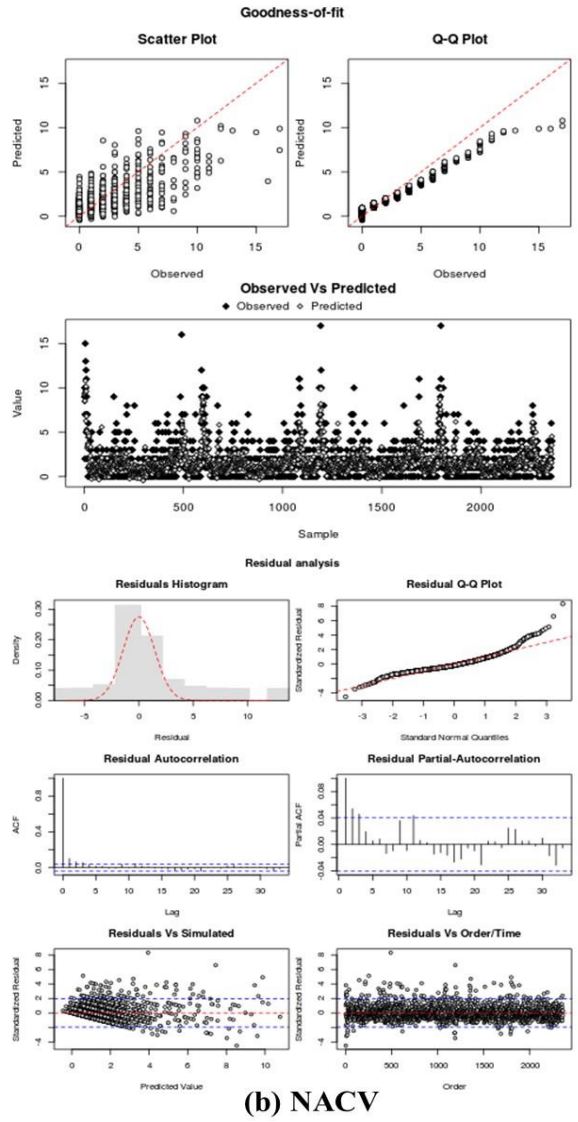
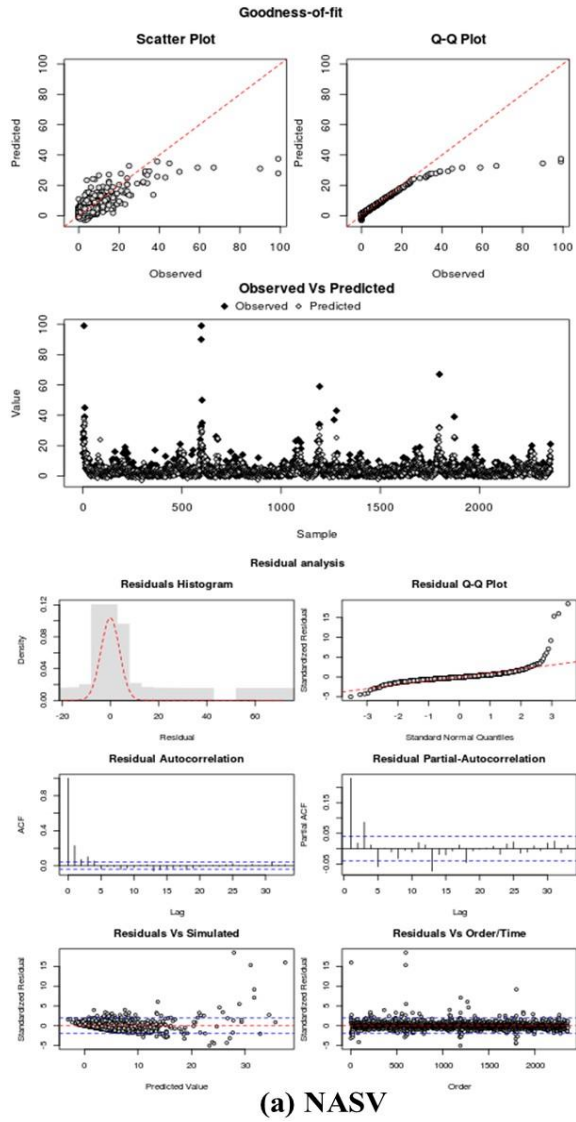
Figura C. 2 - Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_500m\_2015\_2018 (RNA)



**Figura C. 3** – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_3,5km\_2011\_2014 (RNA)

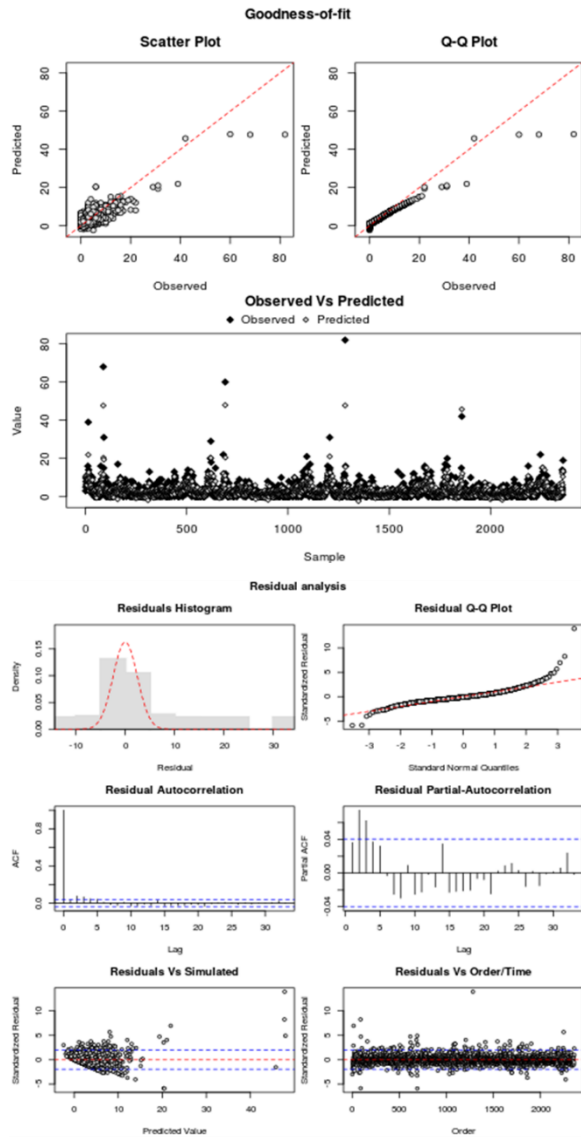


**Figura C. 4** – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_3,5km\_2015\_2018 (RNA)

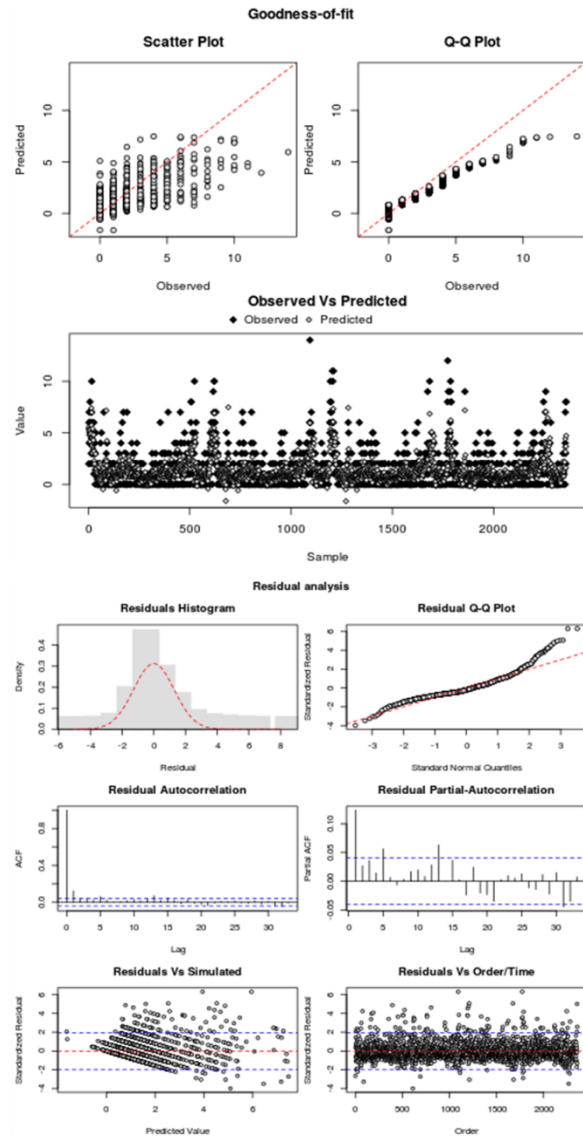


**Figura C. 5** – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS\_500m\_2011\_2014 (RNA)

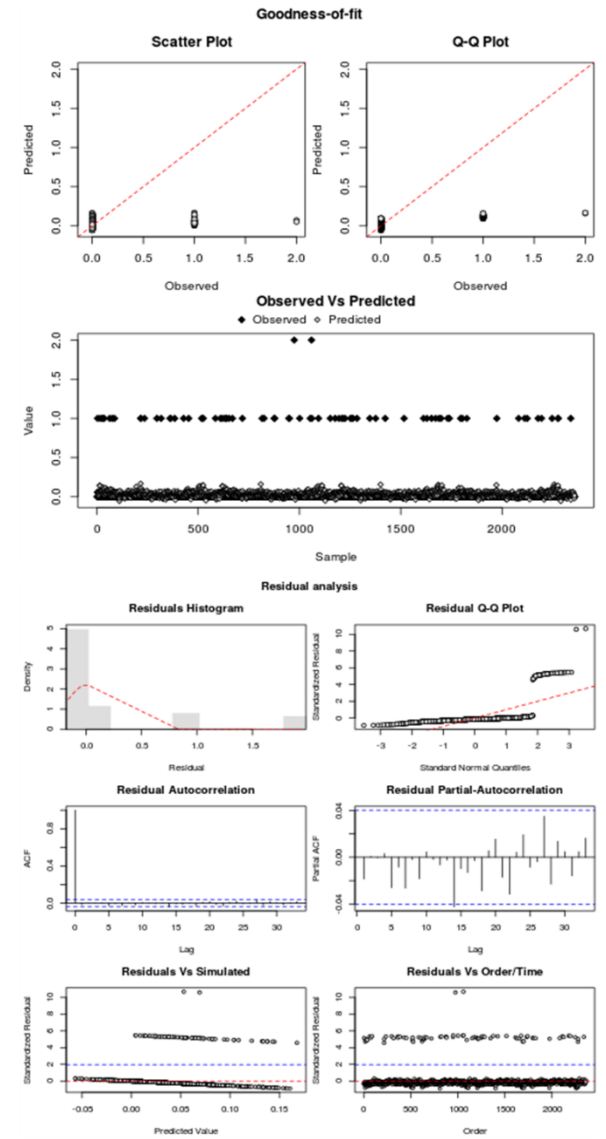




(a) NASV

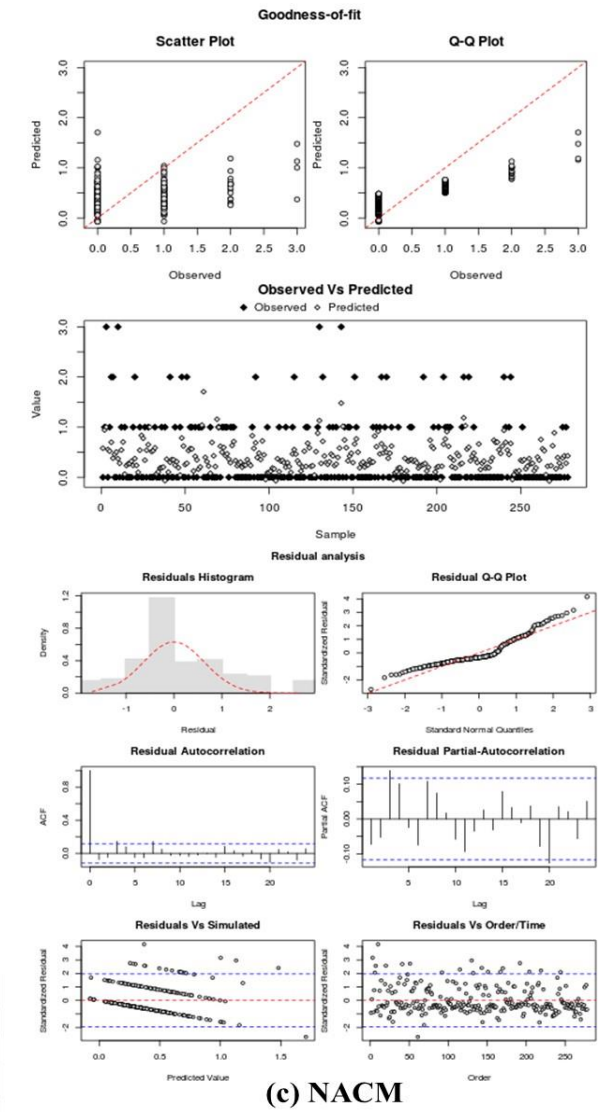
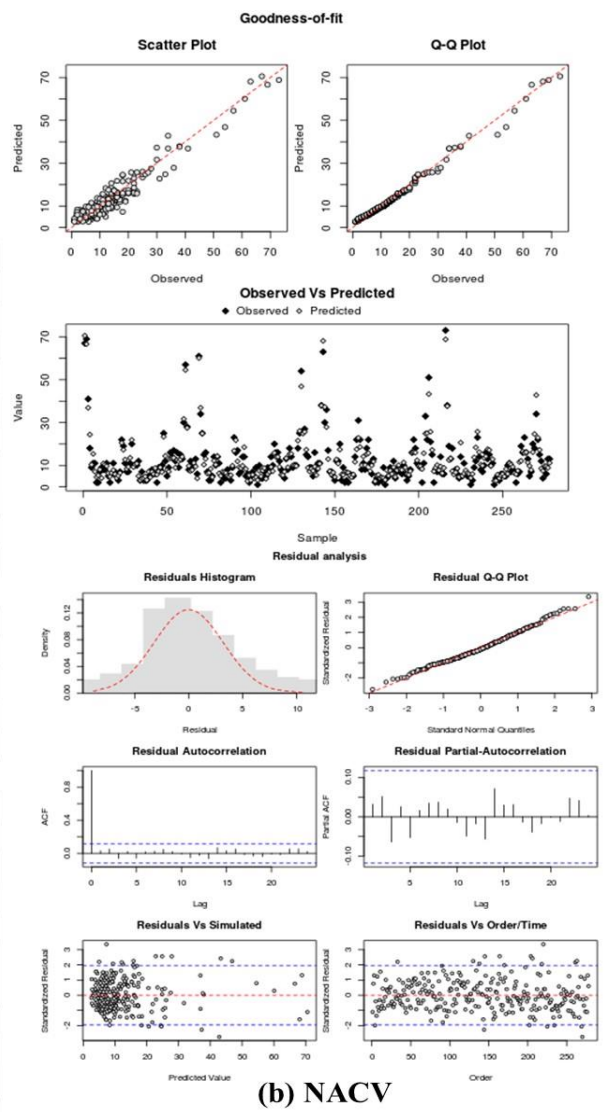
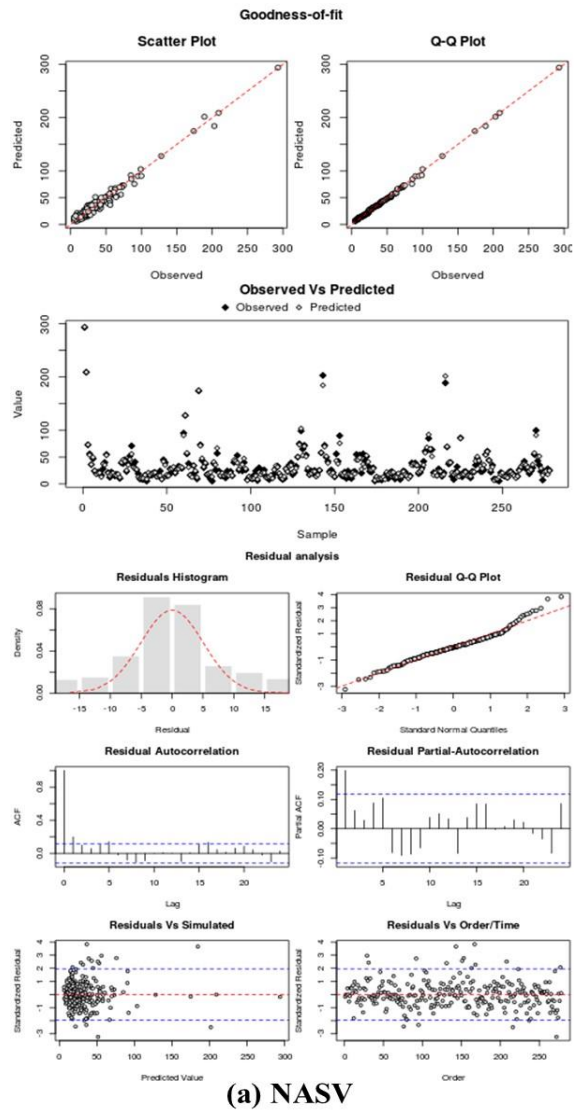


(b) NACV

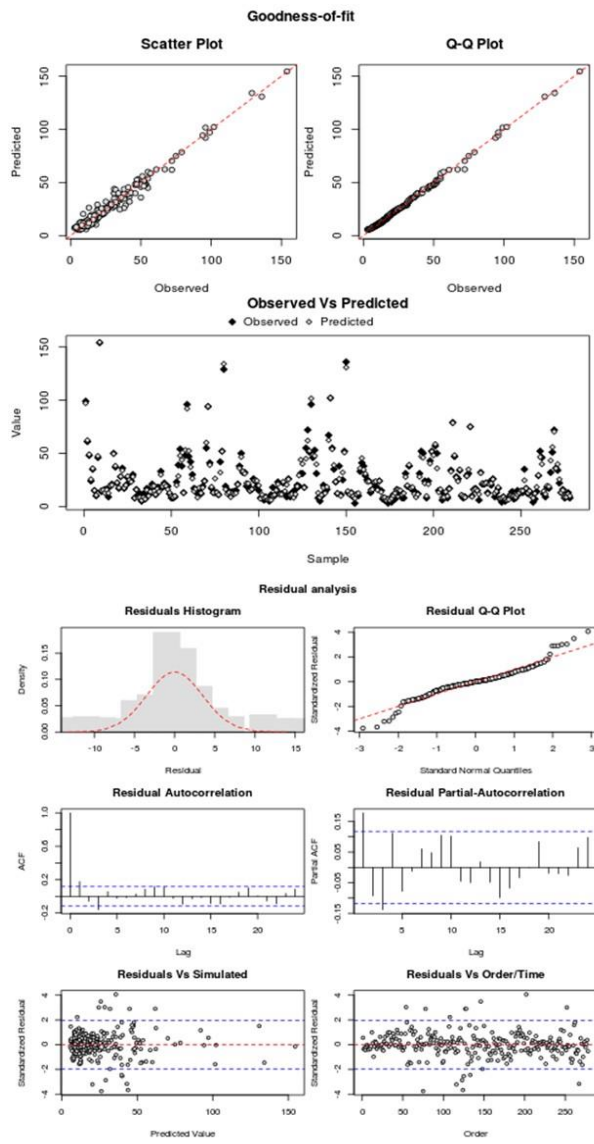


(c) NACM

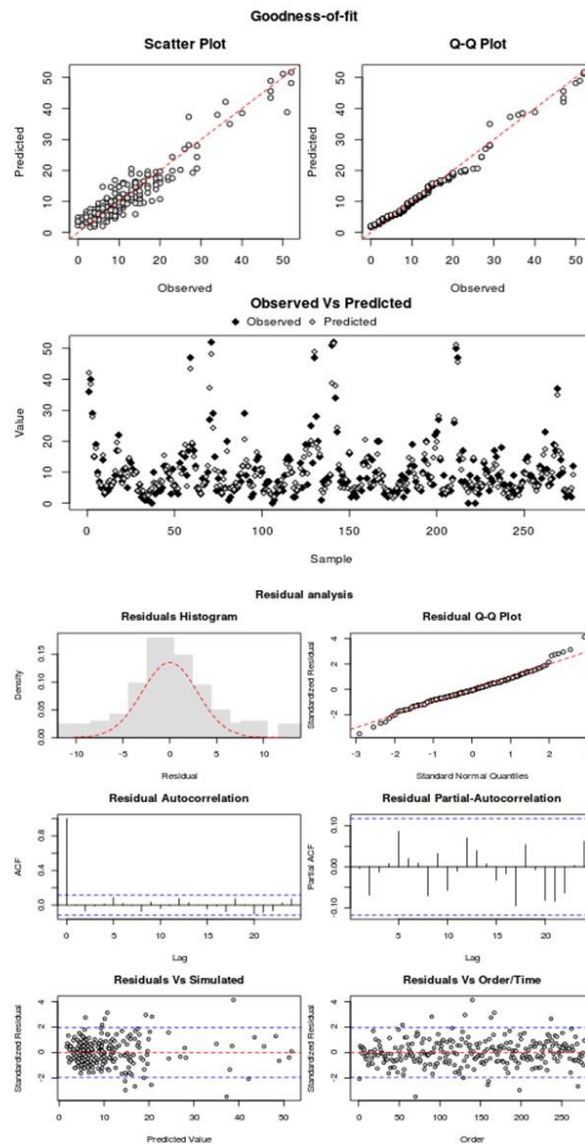
Figura C. 6 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS\_500m\_2015\_2018 (RNA)



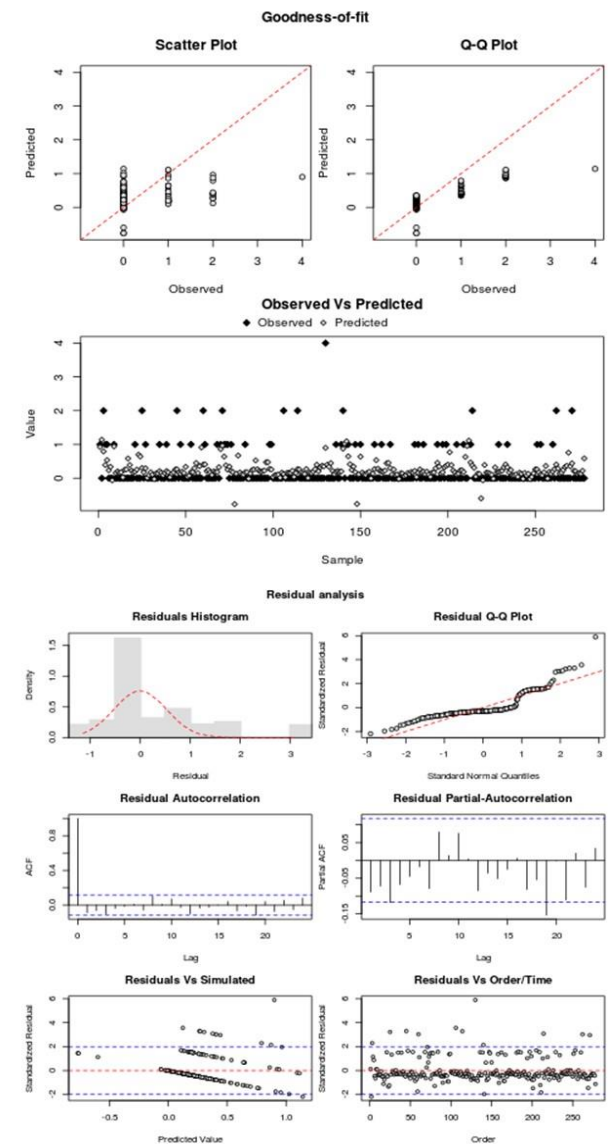
**Figura C. 7** – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS\_4km\_2011\_2014 (RNA)



(a) NASV

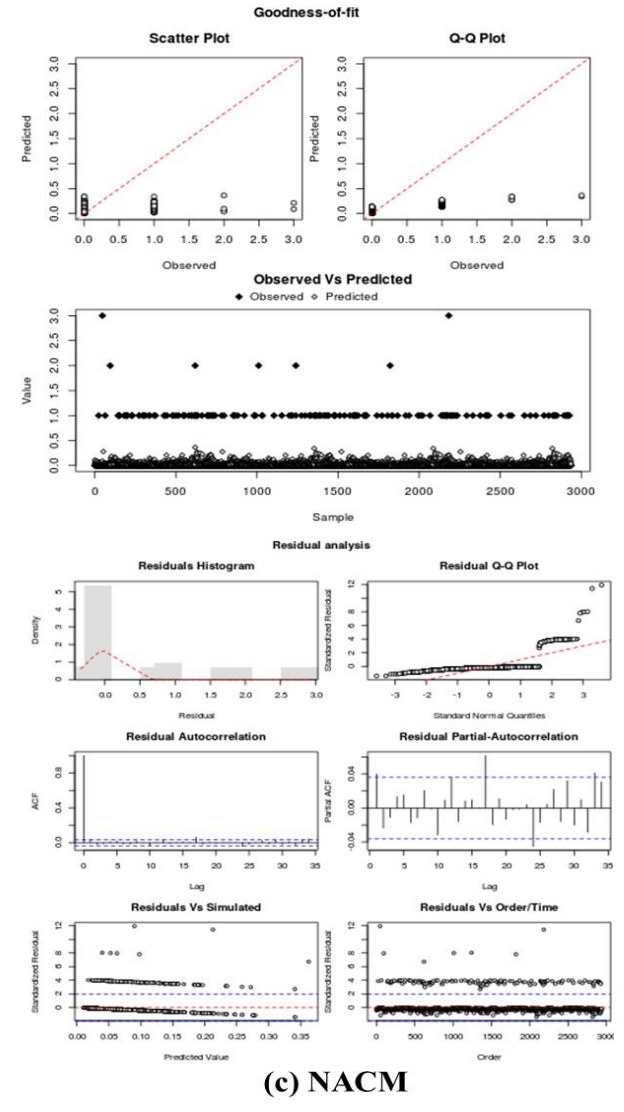
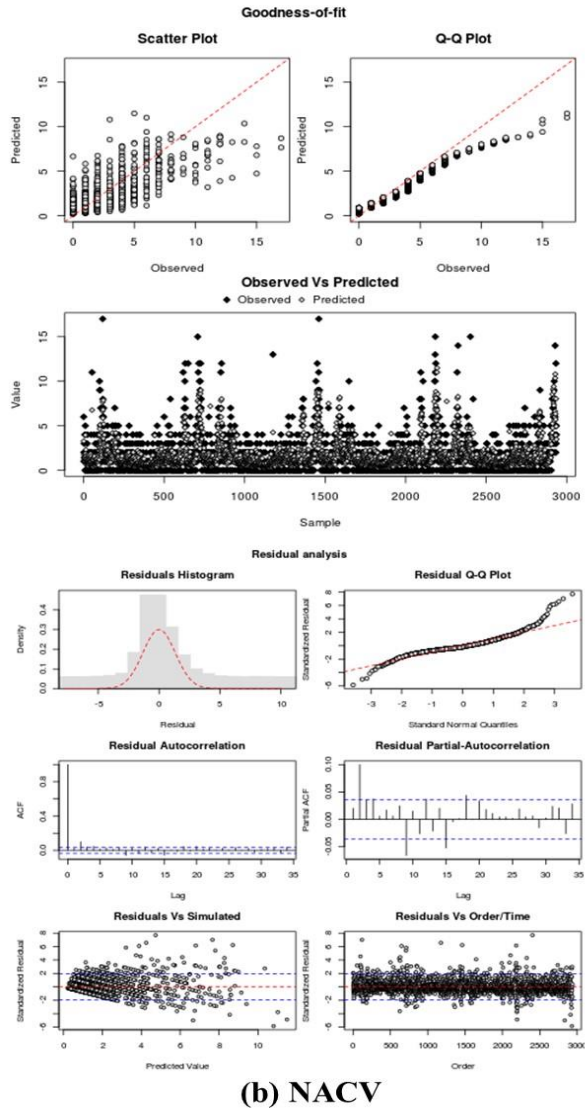
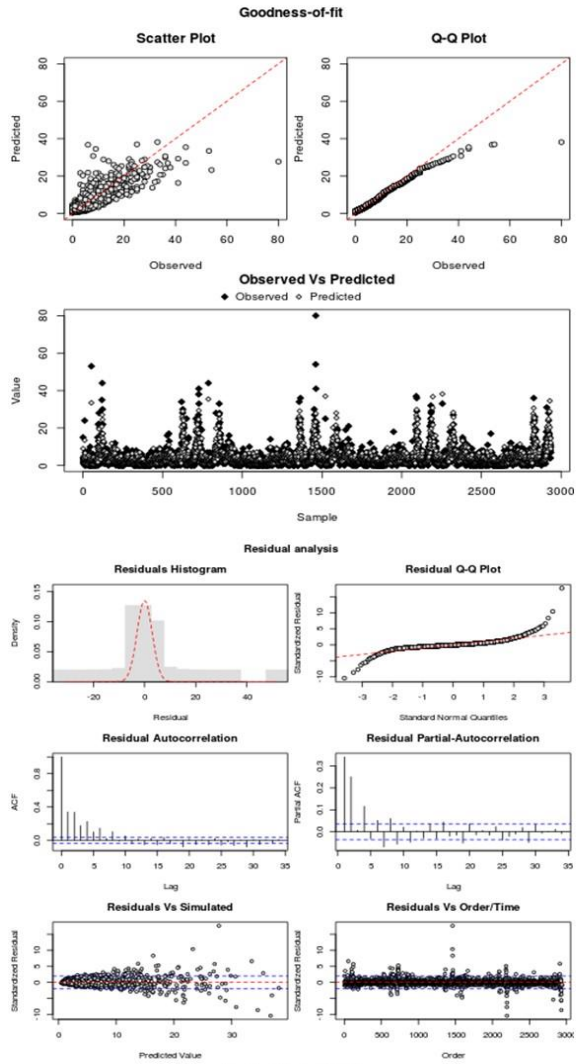


(b) NACV

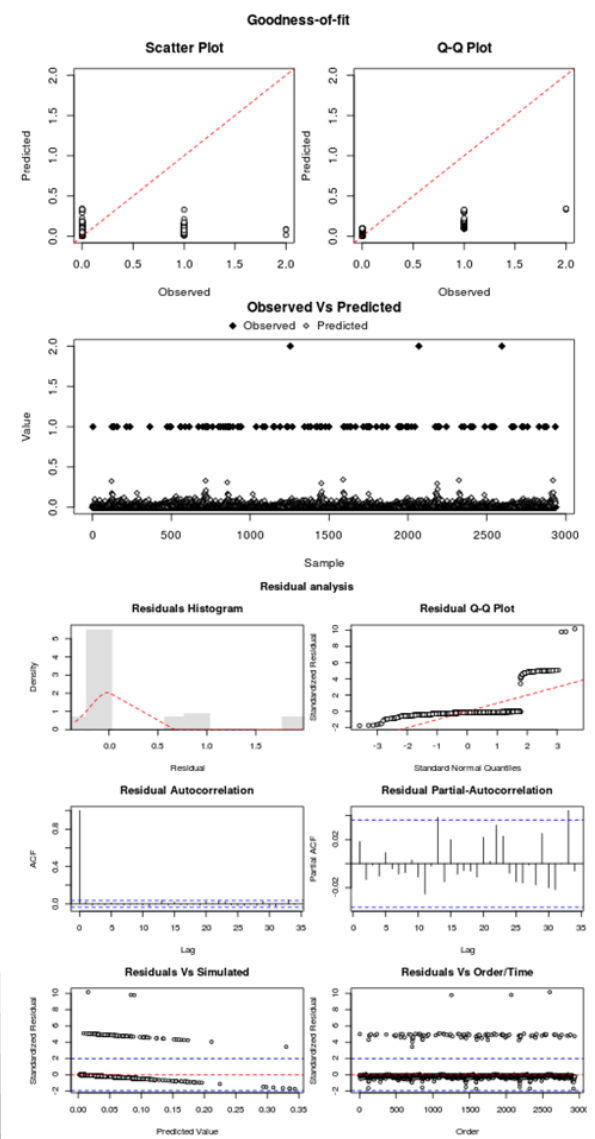
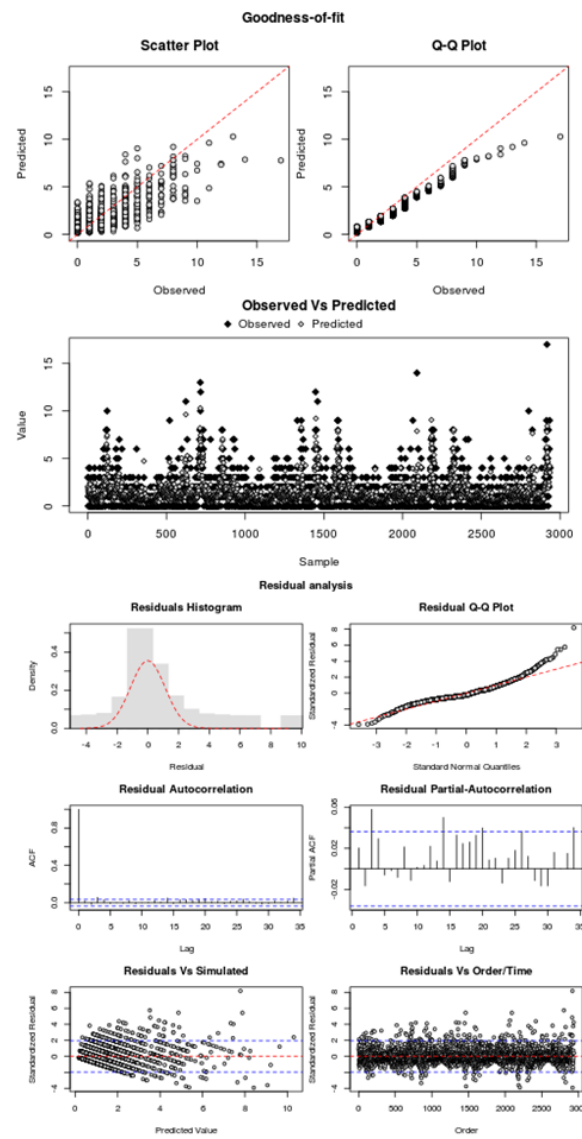
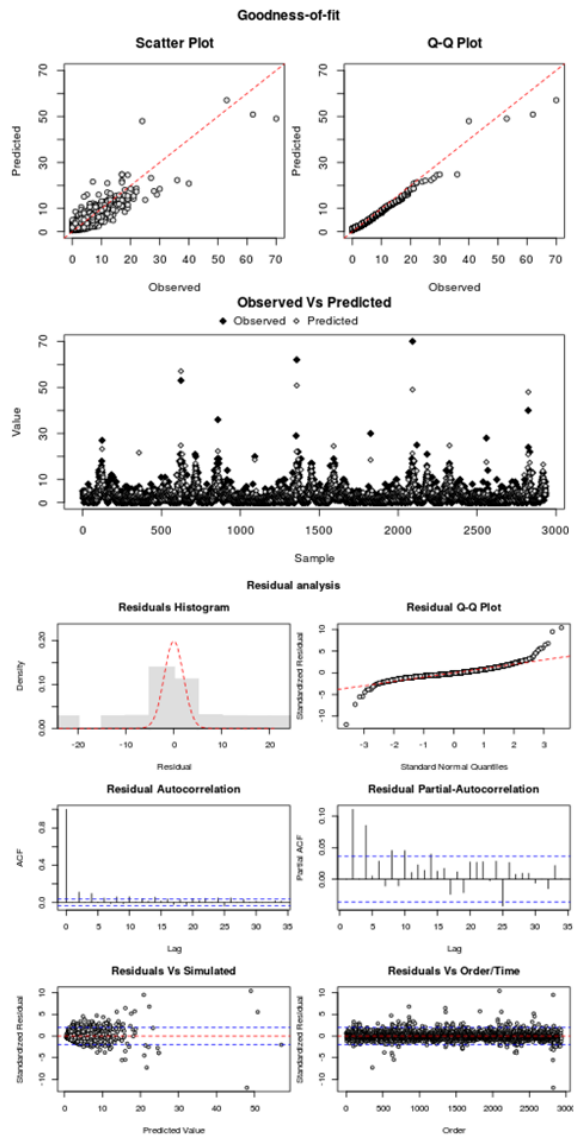


(c) NACM

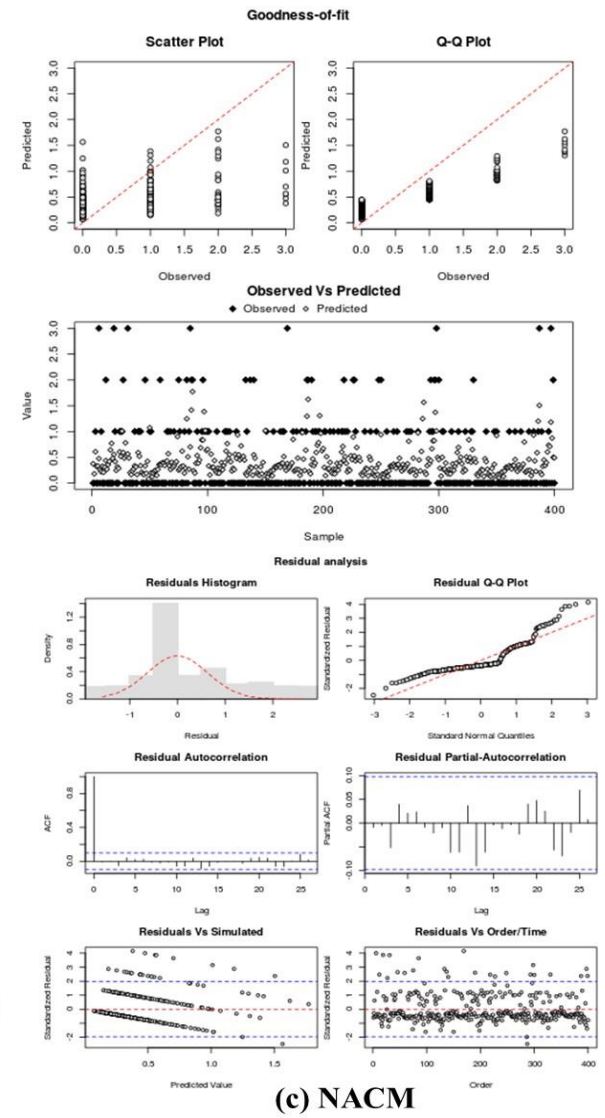
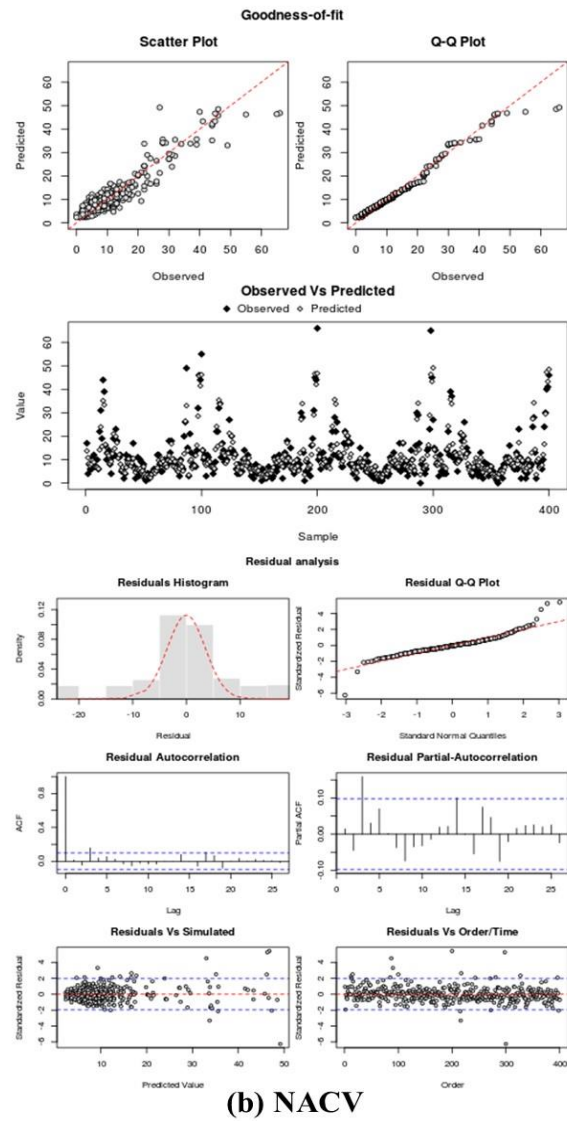
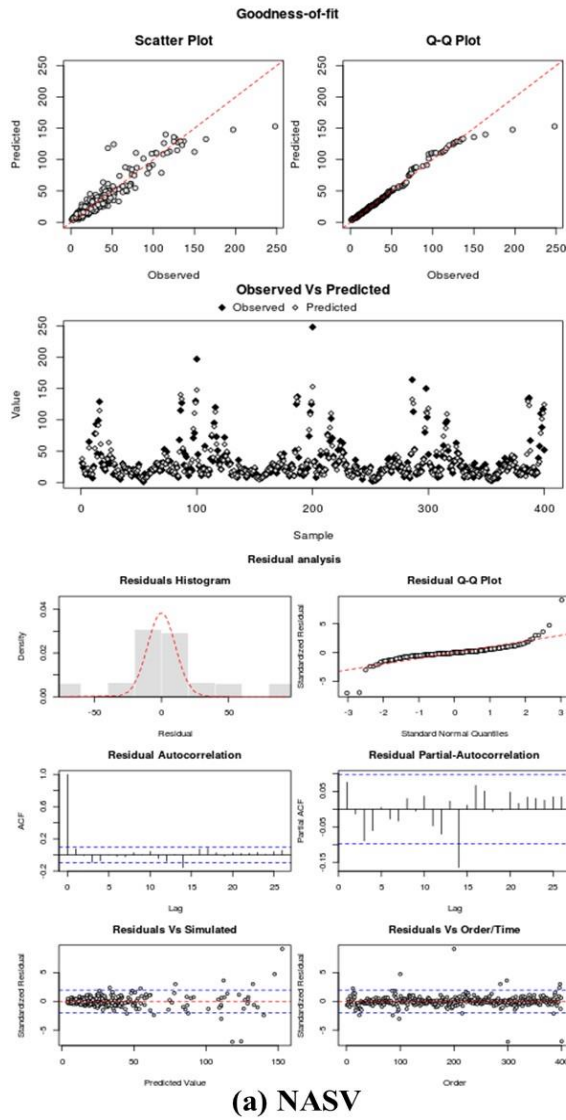
Figura C. 8 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS\_4km\_2015\_2018 (RNA)



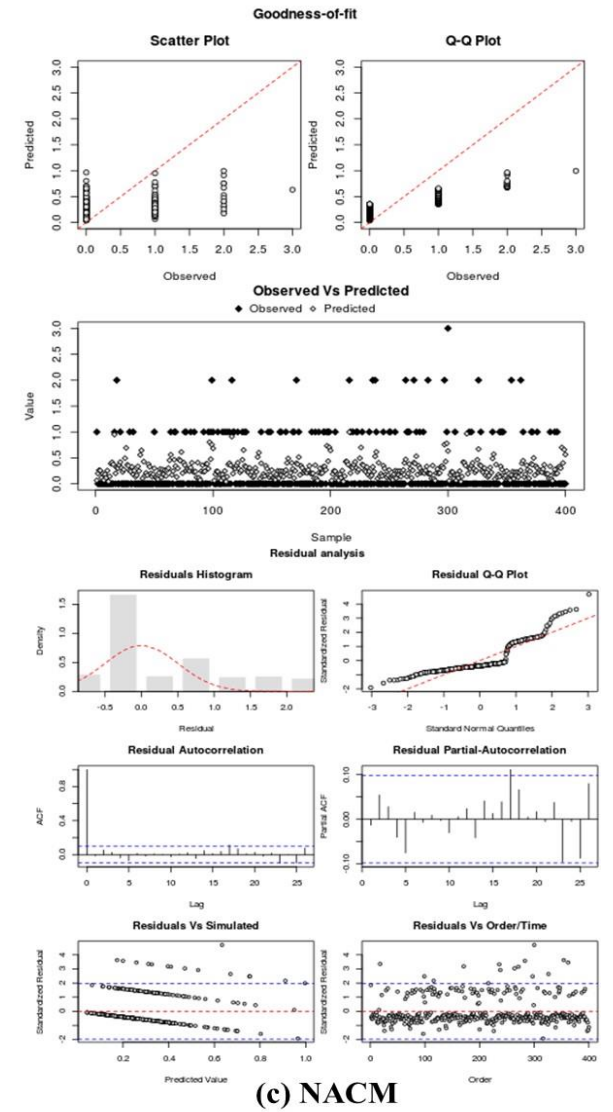
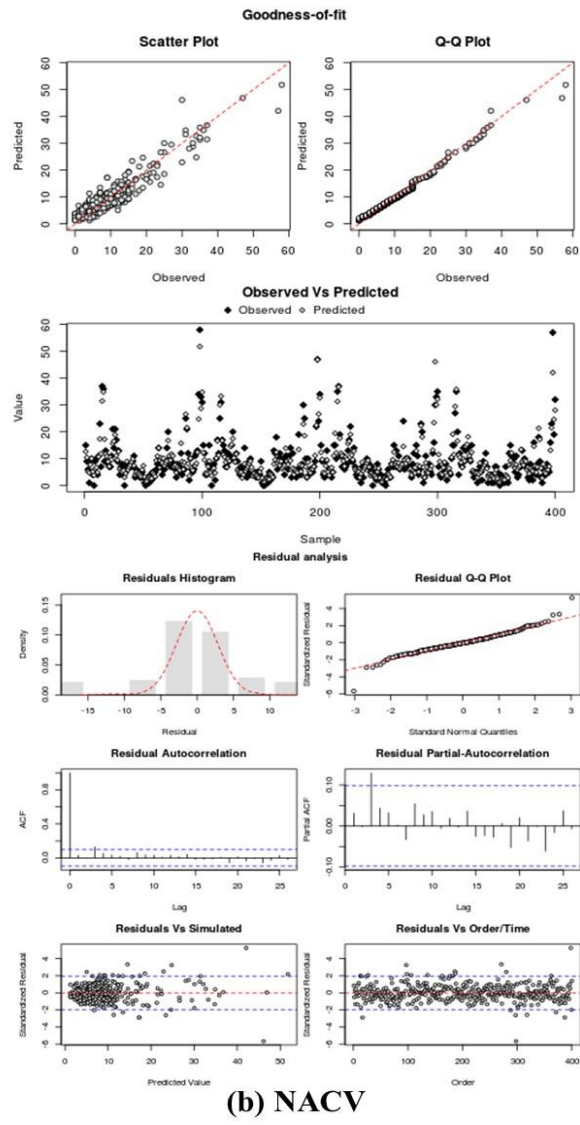
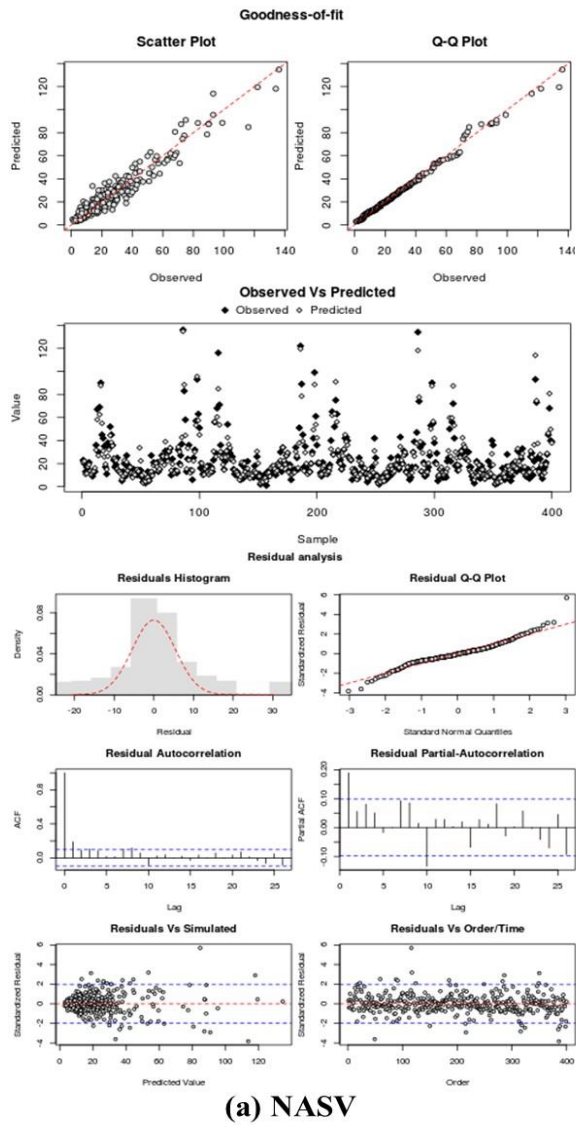
**Figura C. 9** – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_500m\_2011\_2014 (MVPLN)



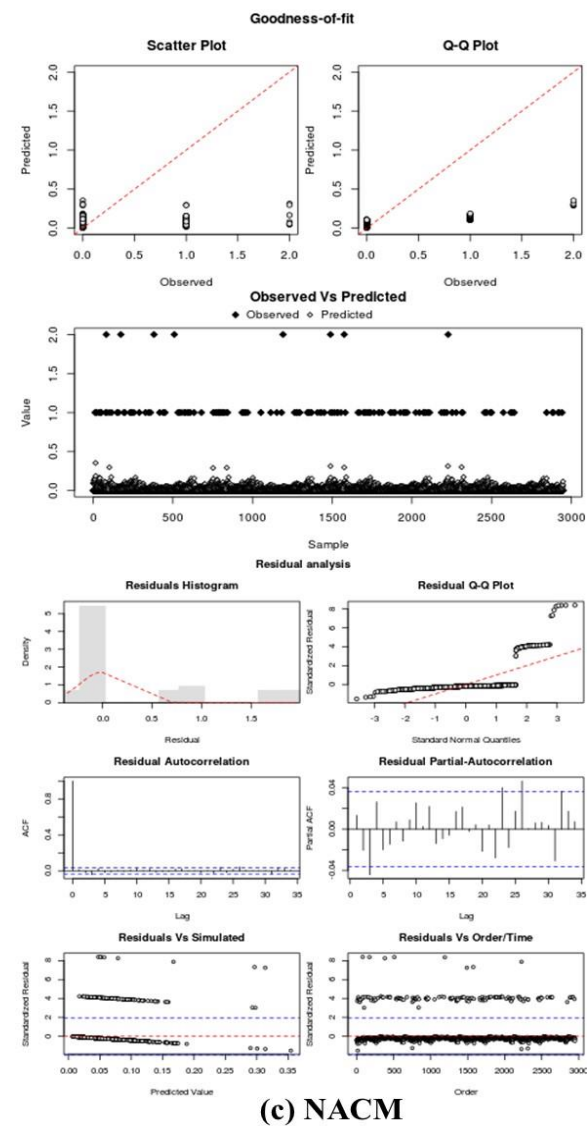
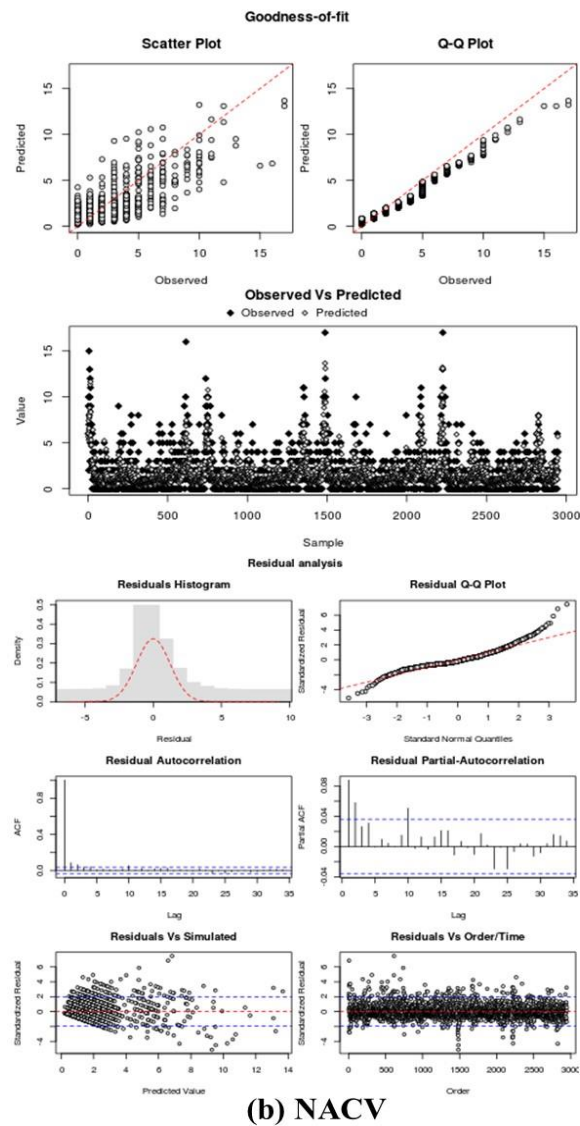
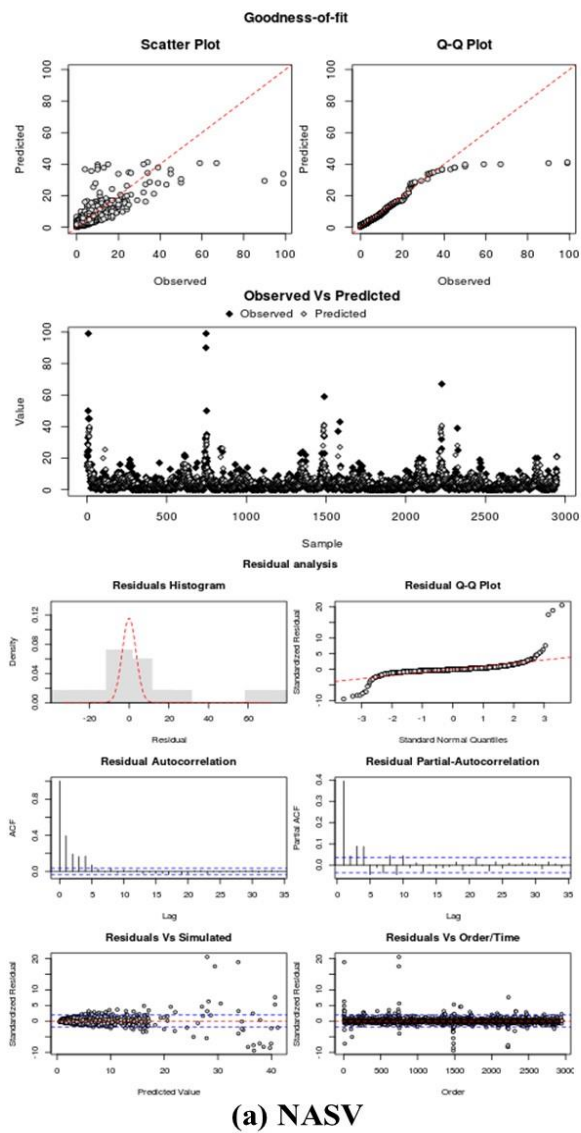
**Figura C. 10** – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_500m\_2015\_2018 (MVPLN)



**Figura C. 11** – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_3,5km\_2011\_2014 (MVPLN)



**Figura C. 12** – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_3,5km\_2015\_2018 (MVPLN)



**Figura C. 13** – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS\_500m\_2011\_2014 (MVPLN)



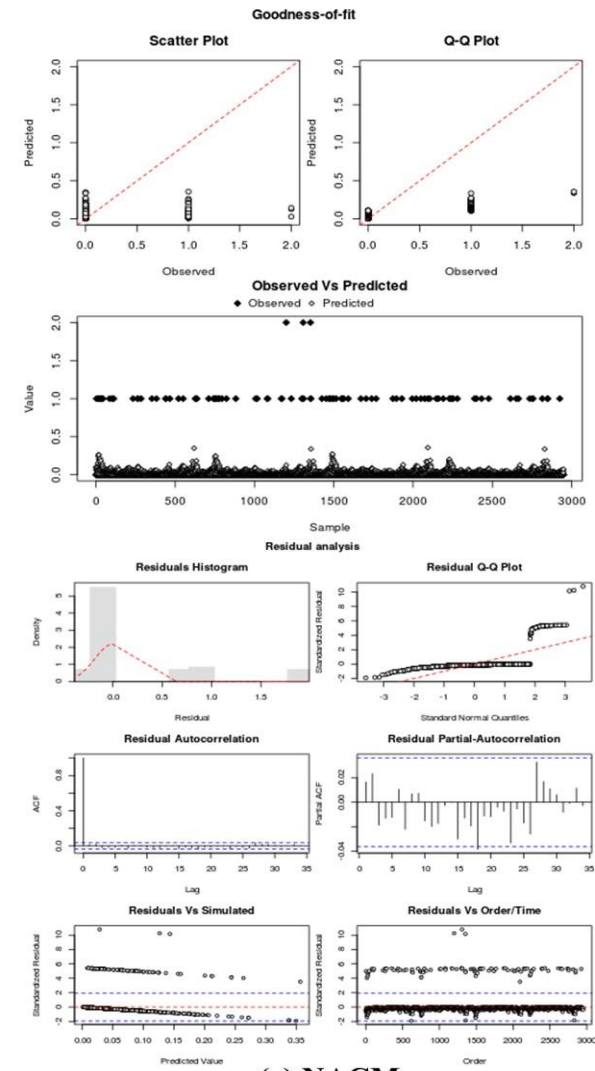
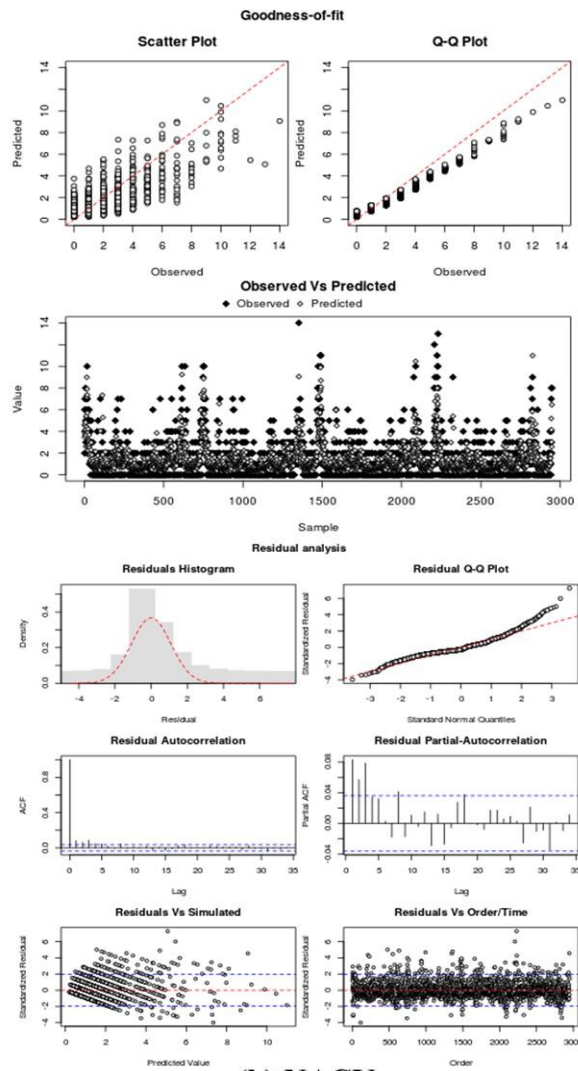
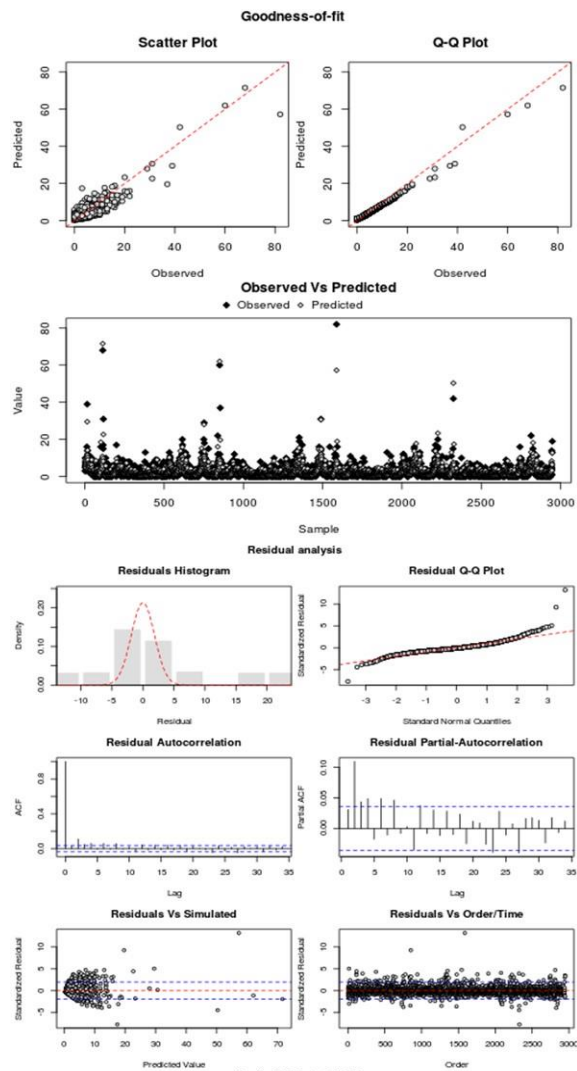
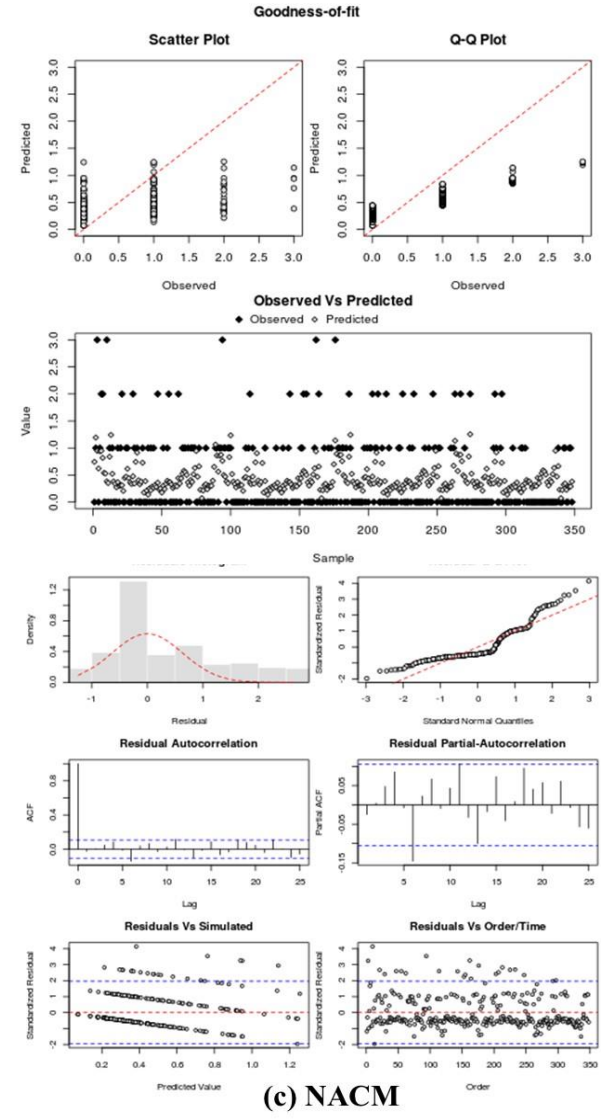
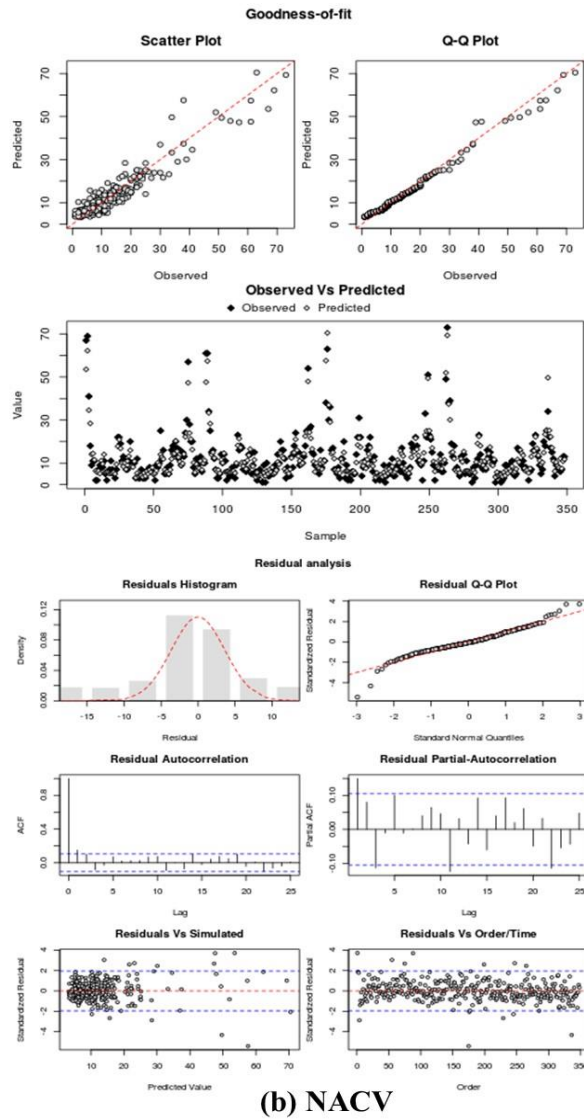
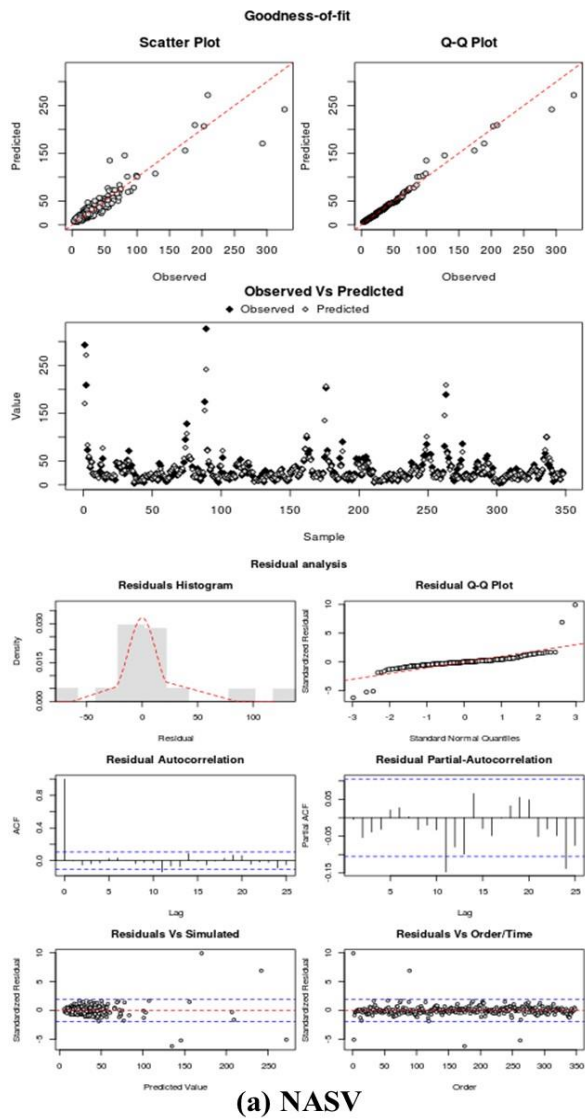
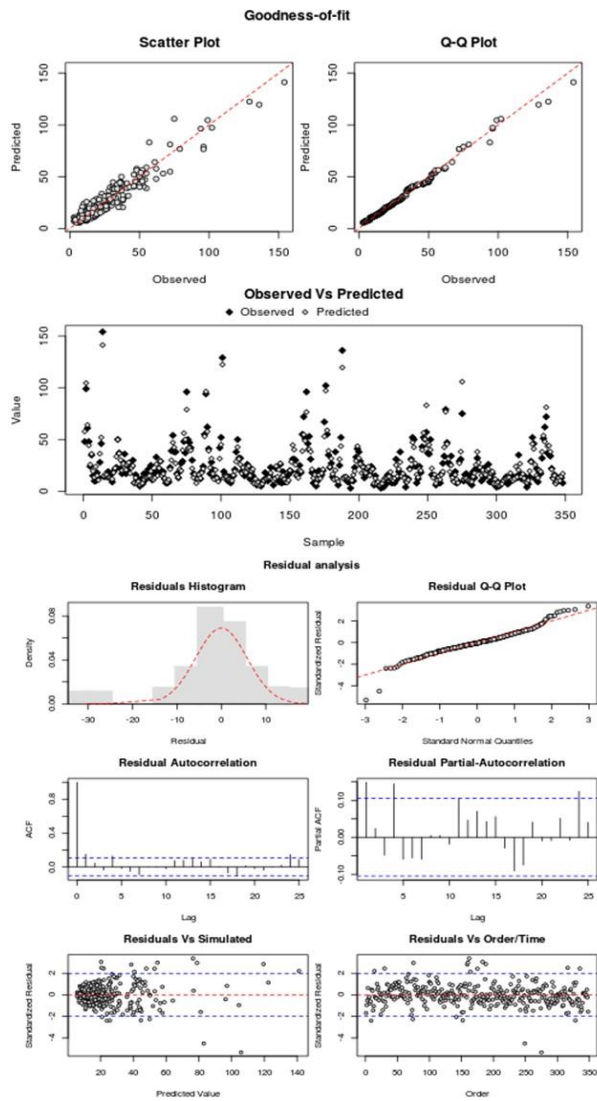


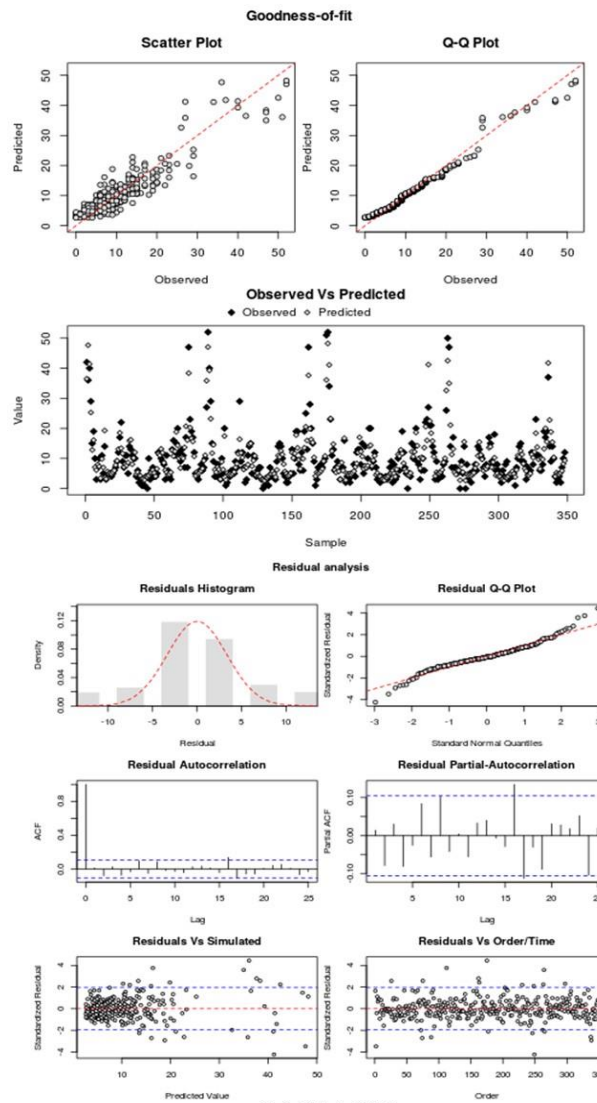
Figura C. 14 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS\_500m\_2015\_2018 (MVPLN)



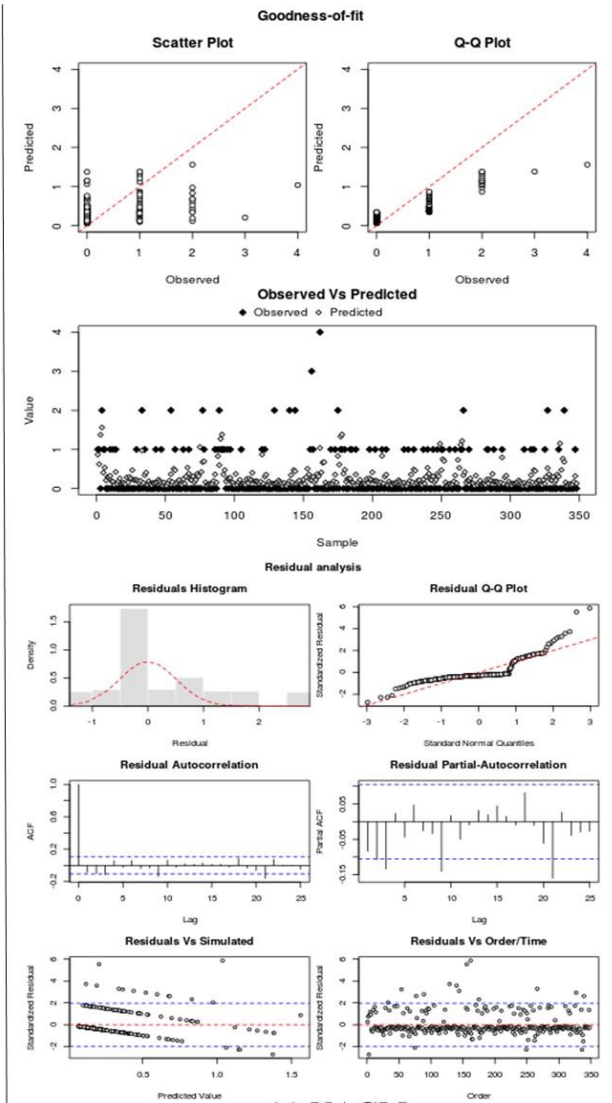
**Figura C. 15** – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS\_4km\_2011\_2014 (MVPLN)



(a) NASV

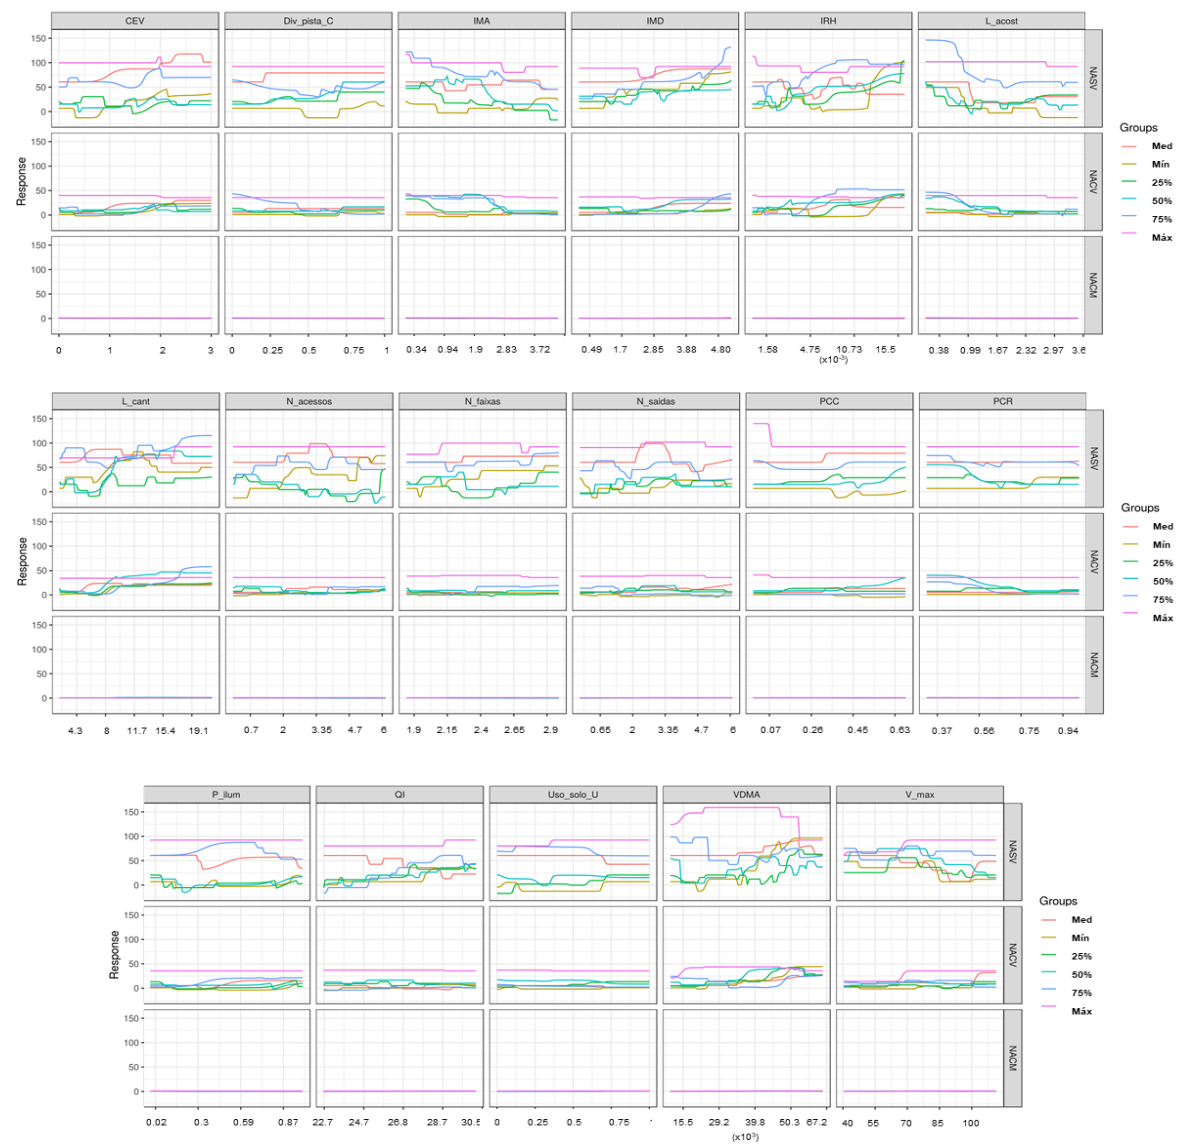


(b) NACV

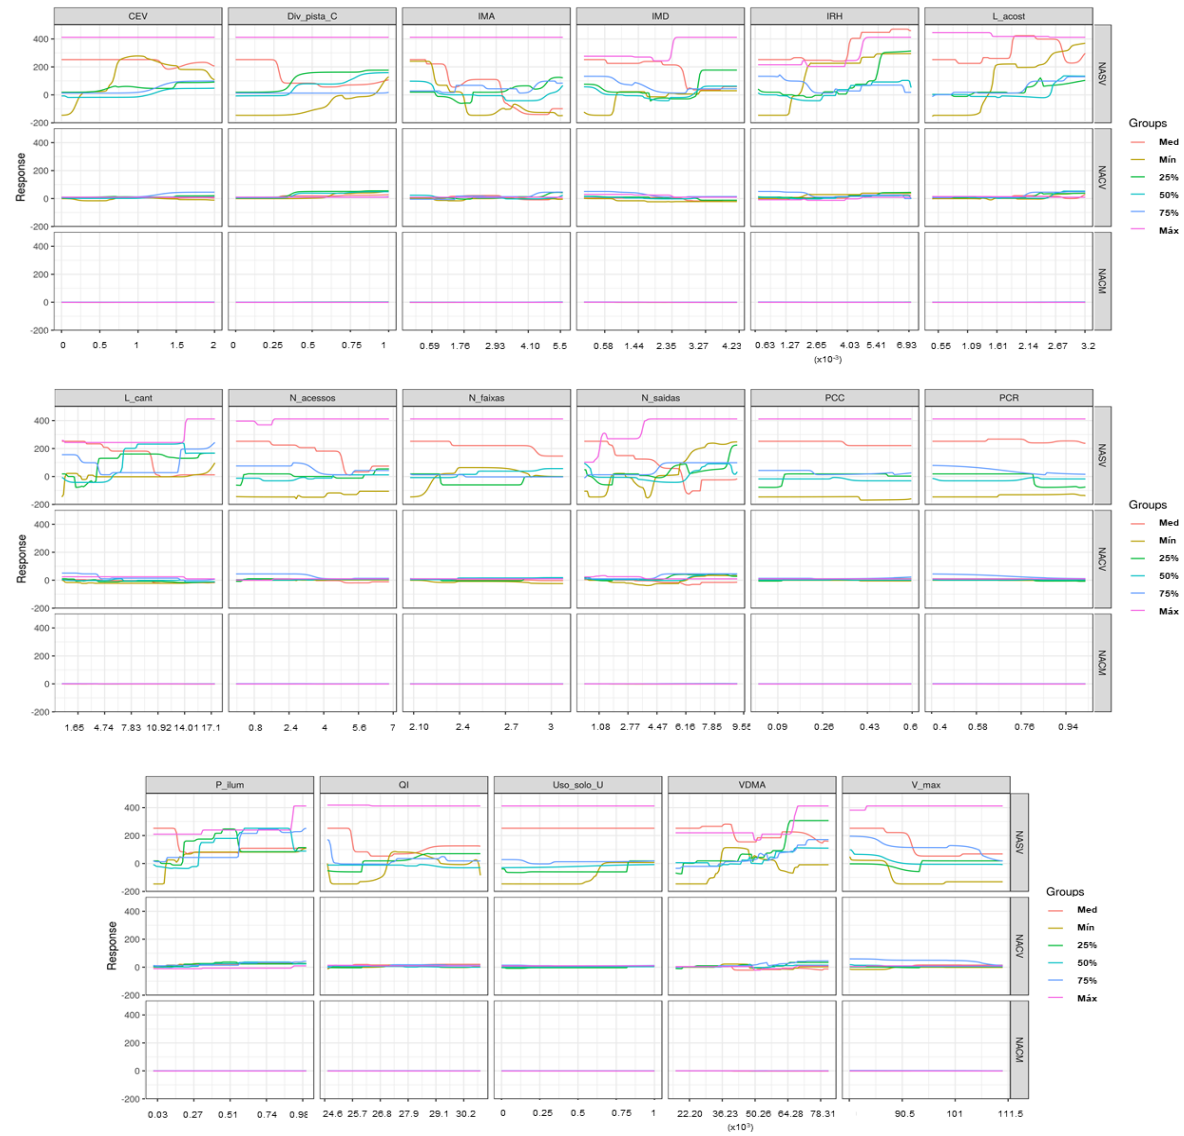


(c) NACM

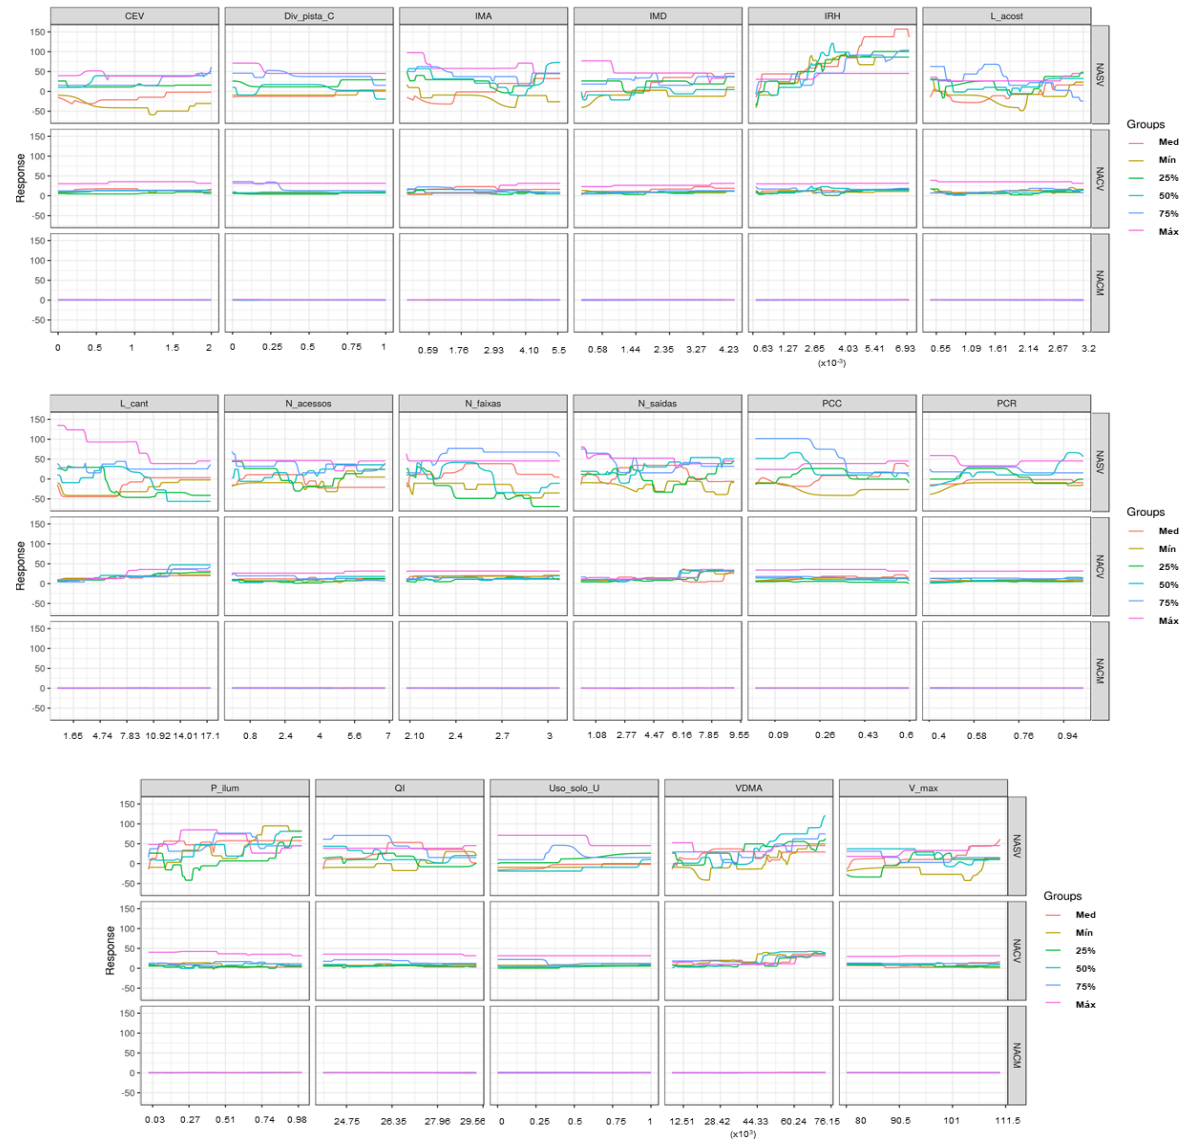
Figura C. 16 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS\_4km\_2015\_2018 (MVPLN)



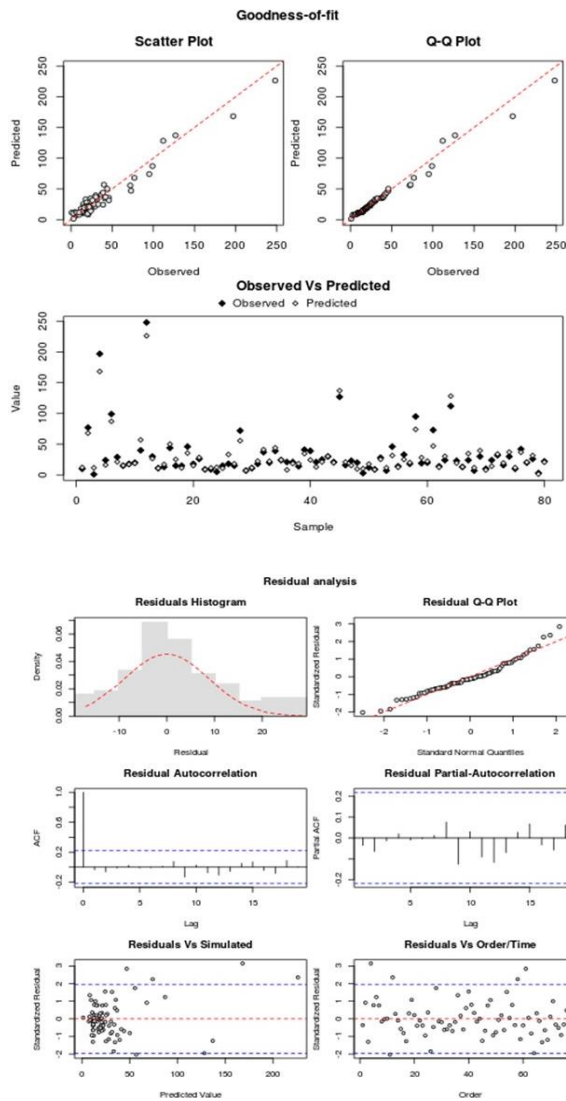
**Figura C. 17**– Perfil de sensibilidade das variáveis explicativas – PN\_3,5km\_2015\_2018



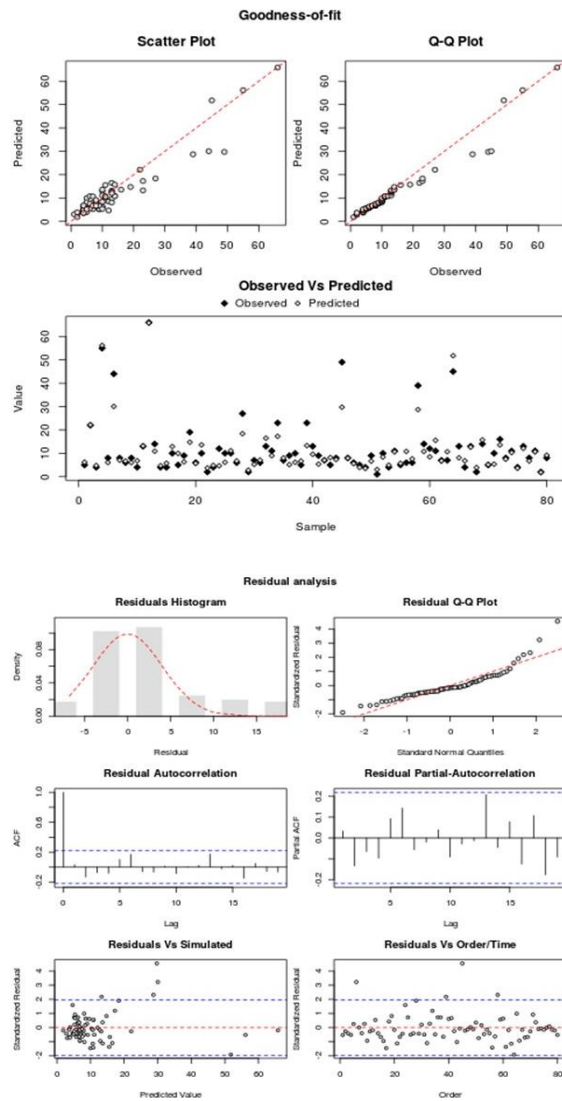
**Figura C. 18** – Perfil de sensibilidade das variáveis explicativas – PS\_4km\_2011\_2014



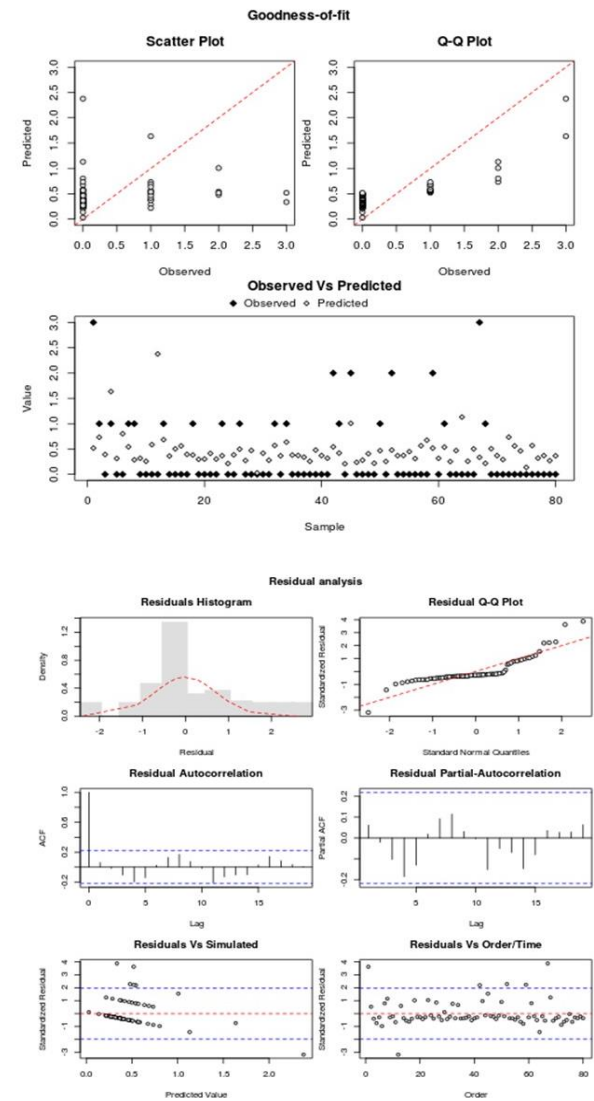
**Figura C. 19** – Perfil de sensibilidade das variáveis explicativas – PS\_4km\_2015\_2018



(a) NASV

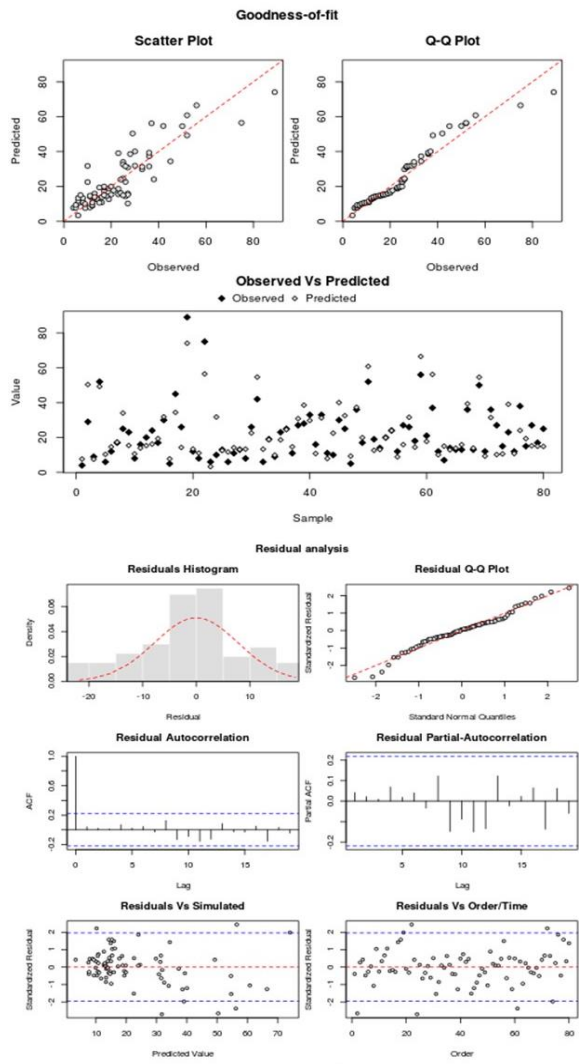


(b) NACV

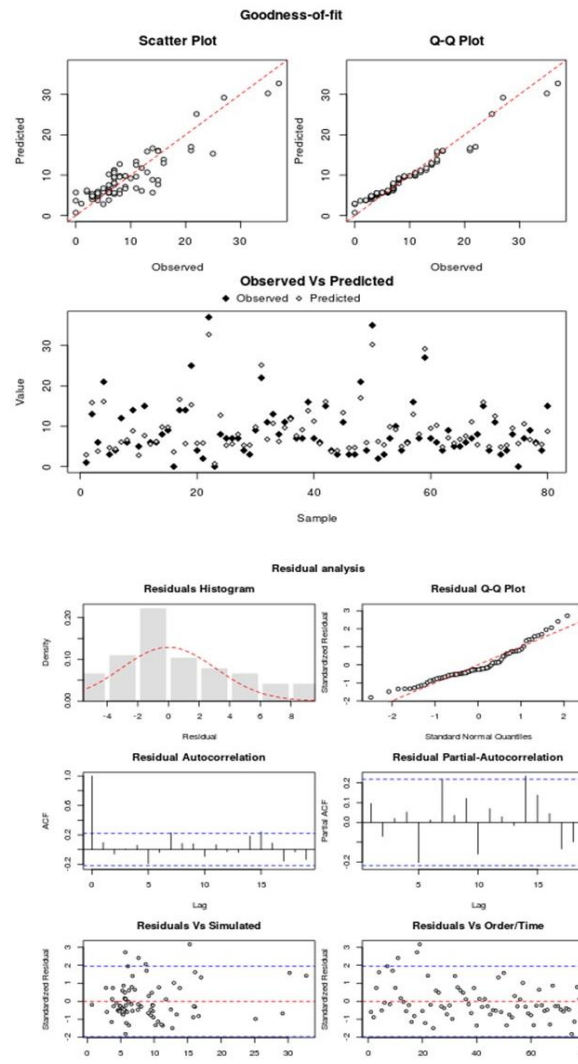


(c) NACM

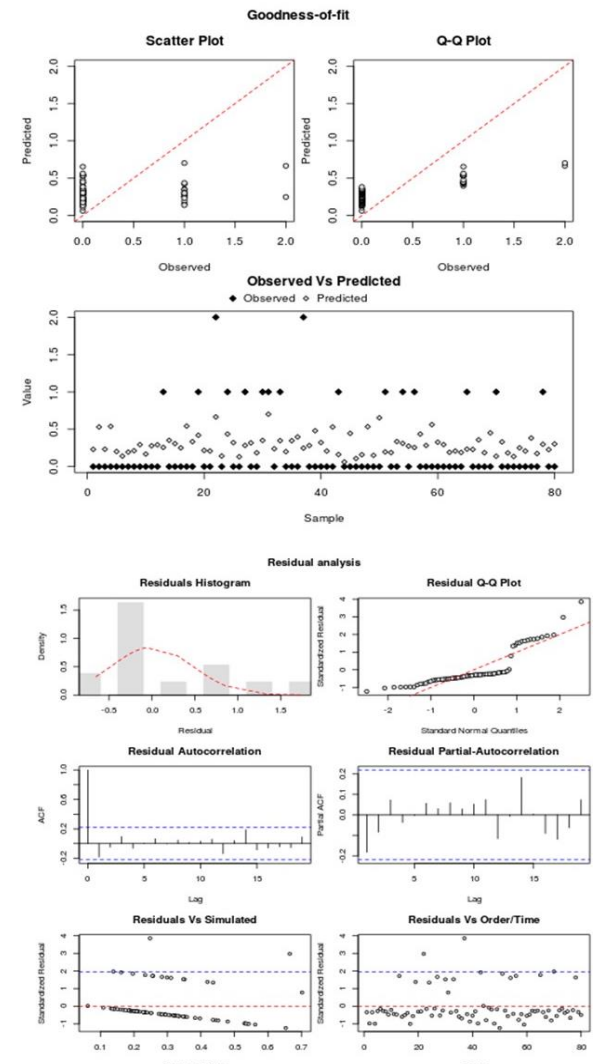
Figura C. 20 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_3,5km\_2011\_2014 (RNA – validação)



(a) NASV



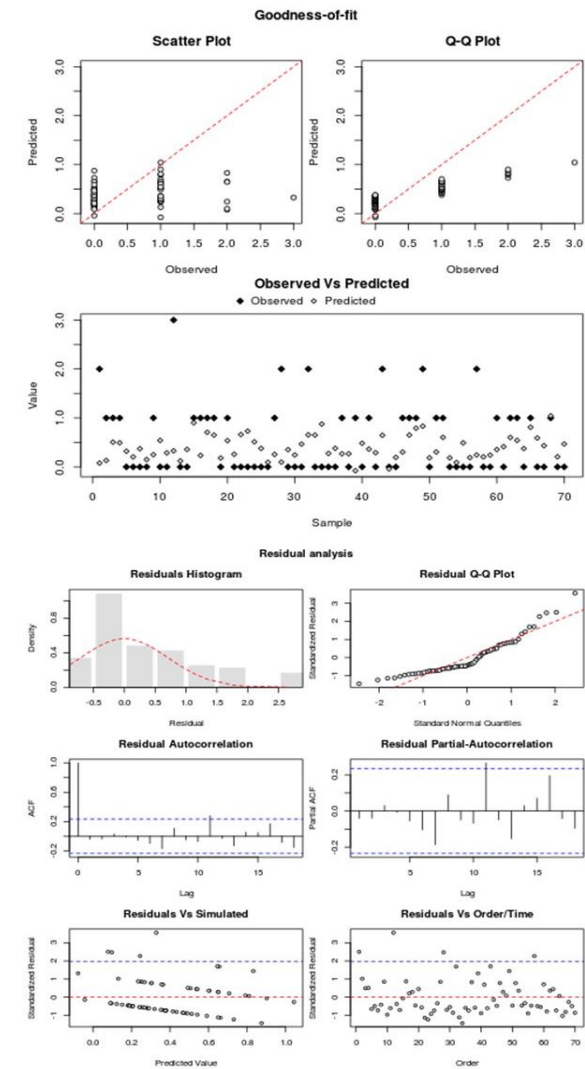
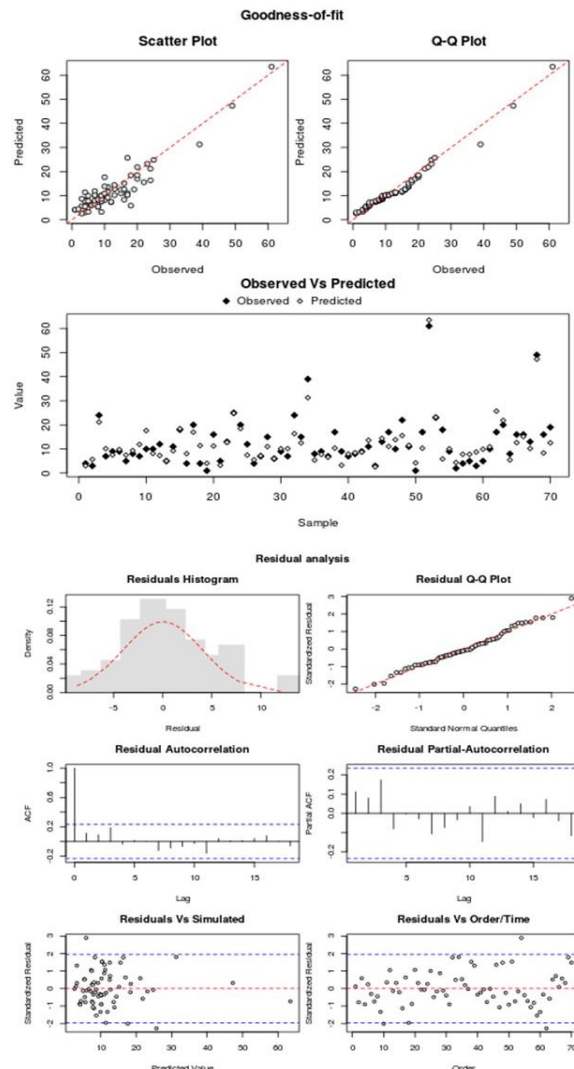
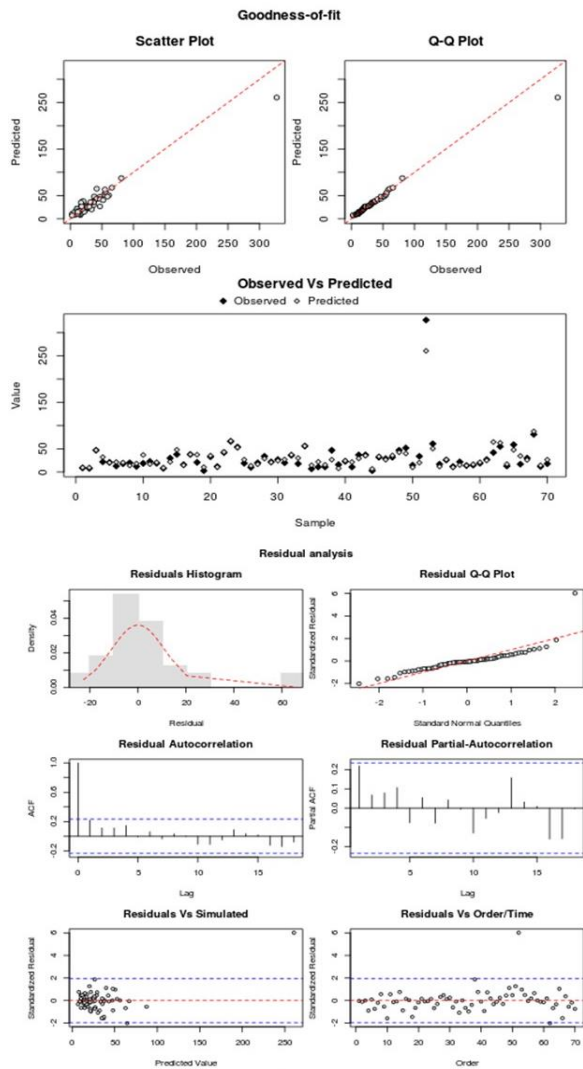
(b) NACV



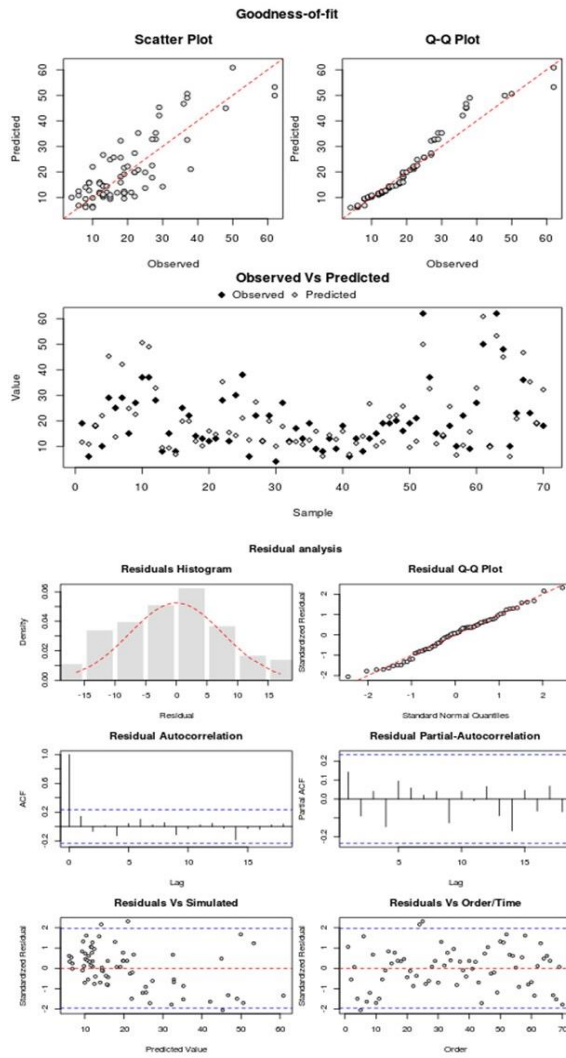
(c) NACM

Figura C. 21 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_3,5km\_2015\_2018 (RNA – validação)

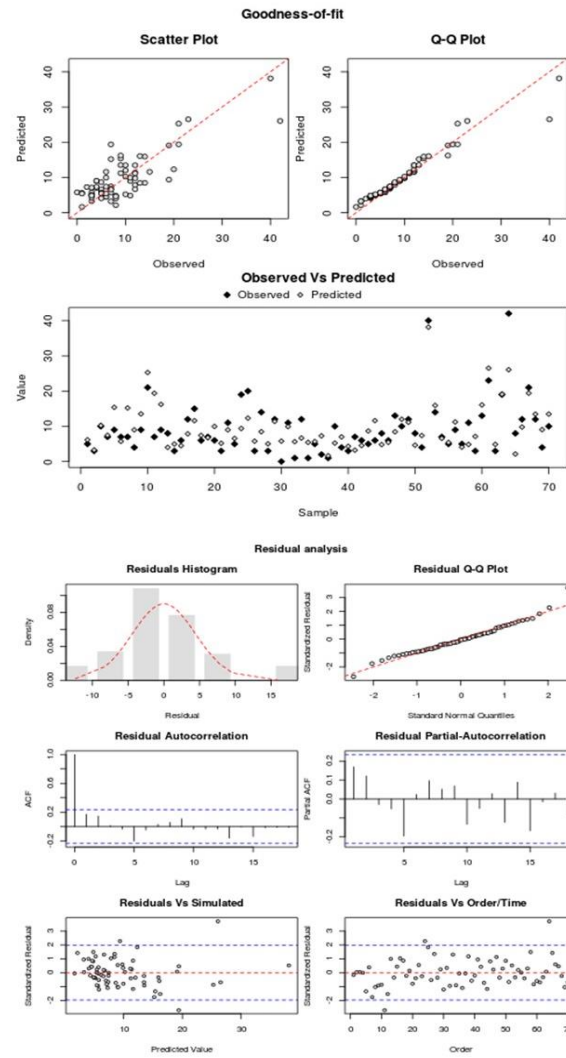




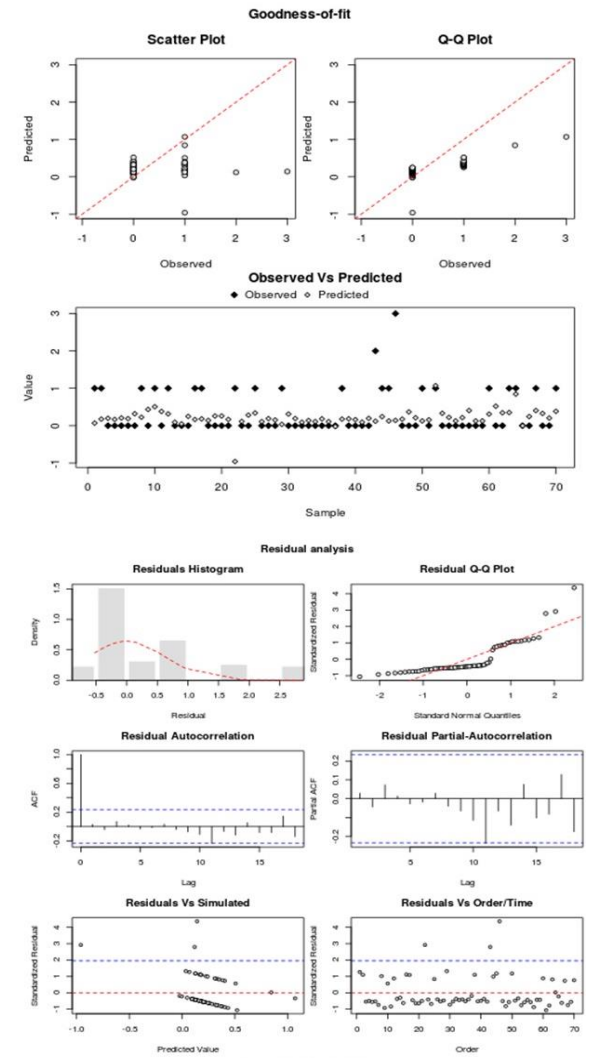
**Figura C. 22** – Qualidade de ajuste (*goodness-of-fit*) e análise de resíduos para PS\_4km\_2011\_2014 (RNA – validação)



(a) NASV

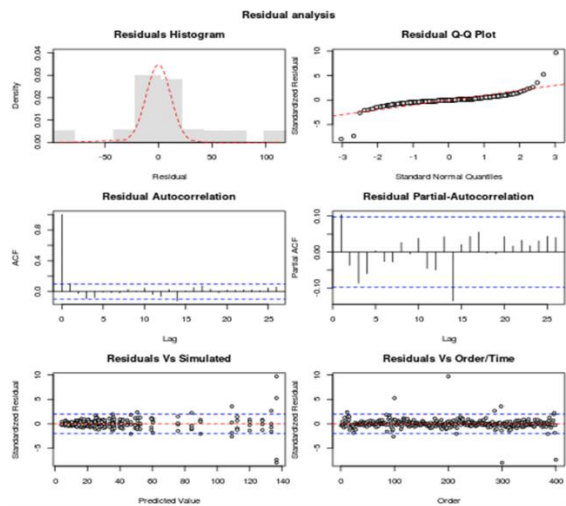
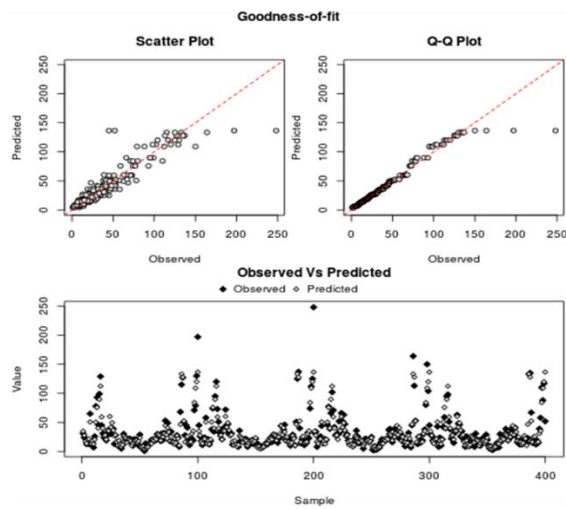


(b) NACV

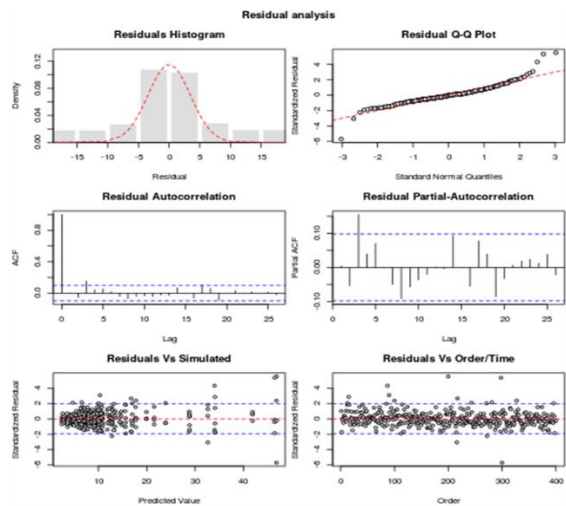
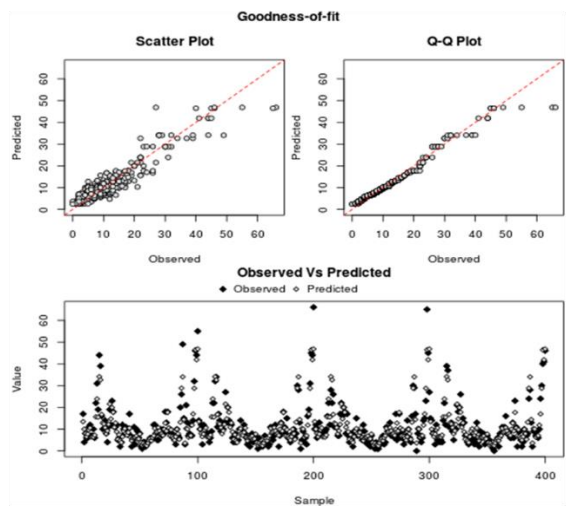


(c) NACM

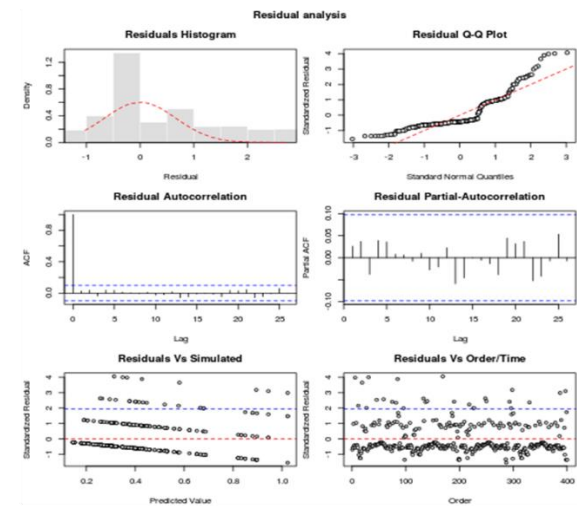

**Figura C. 23 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS\_4km\_2015\_2018 (RNA – validação)**



(a) NASV

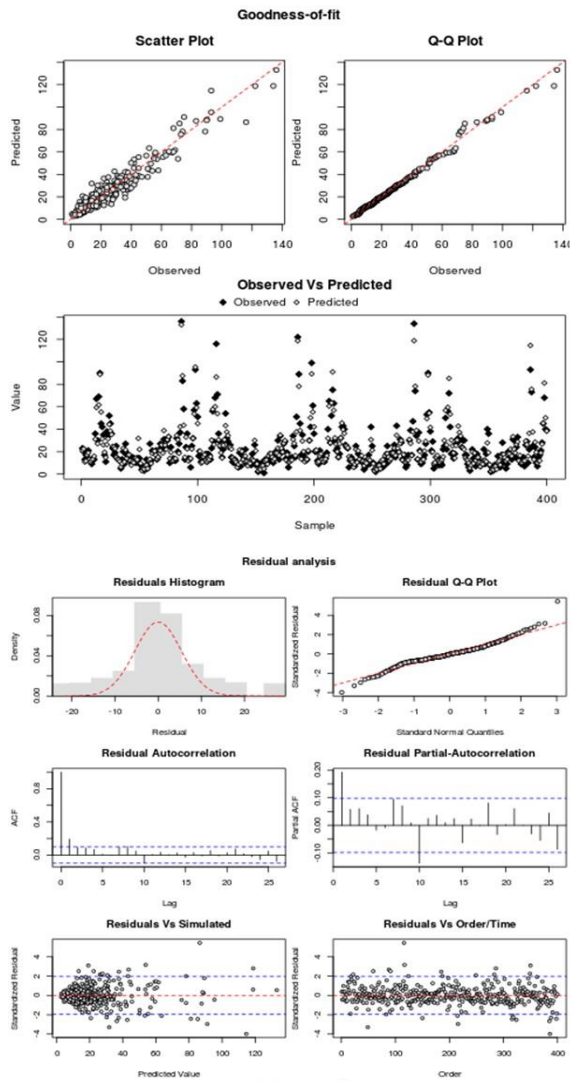


(b) NACV

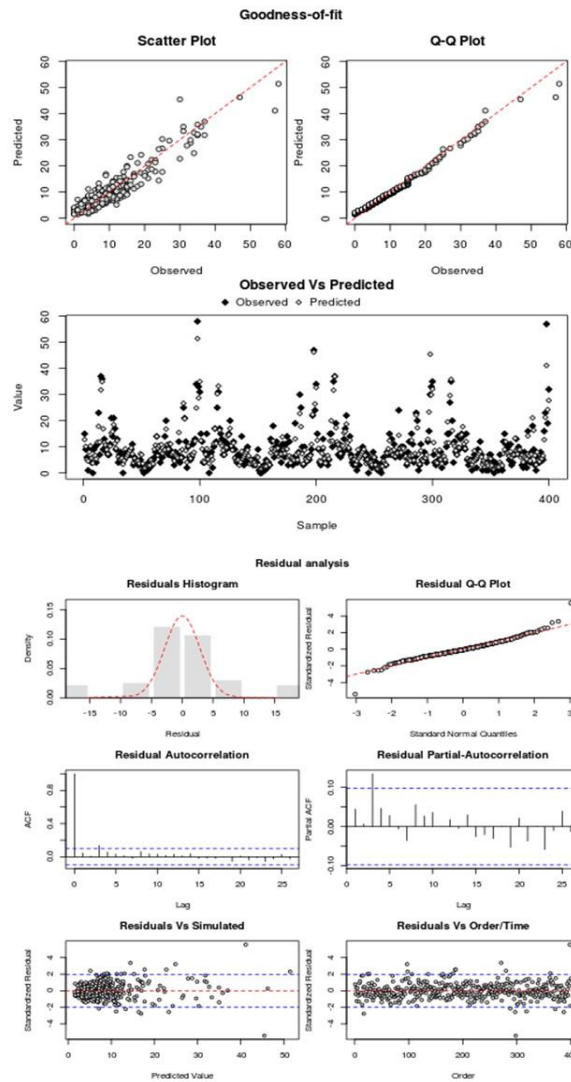


(c) NACM

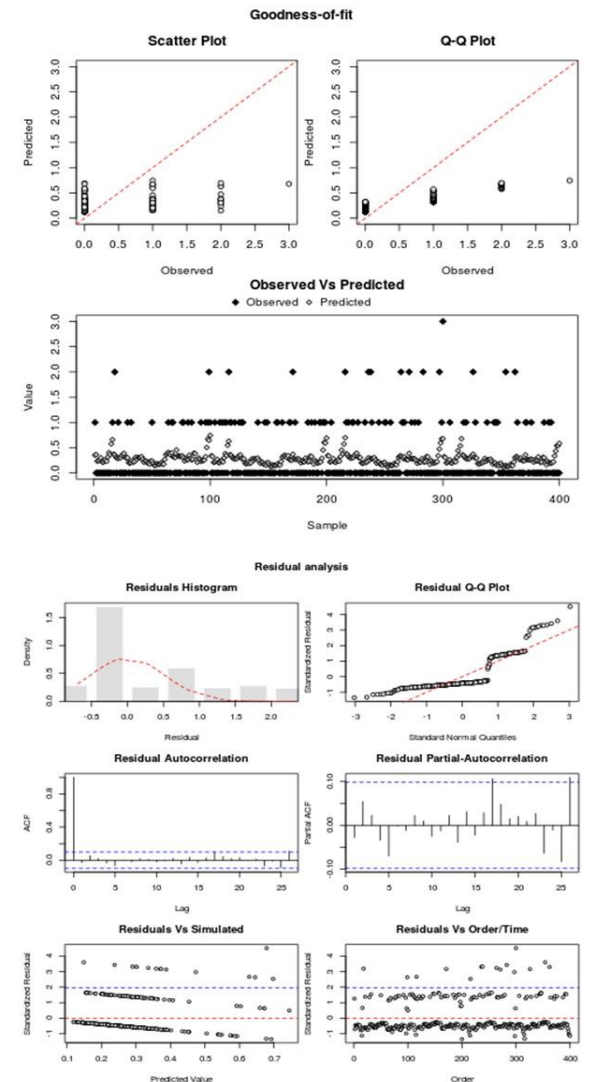
Figura C. 24 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_3,5km\_2011\_2014 (MVPLN – backward)



(a) NASV

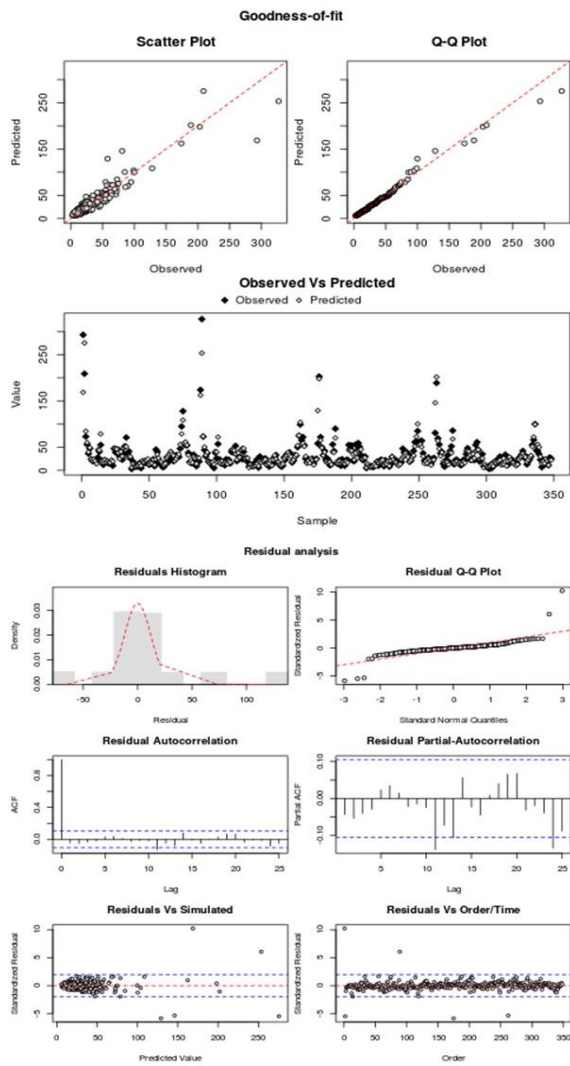


(b) NACV

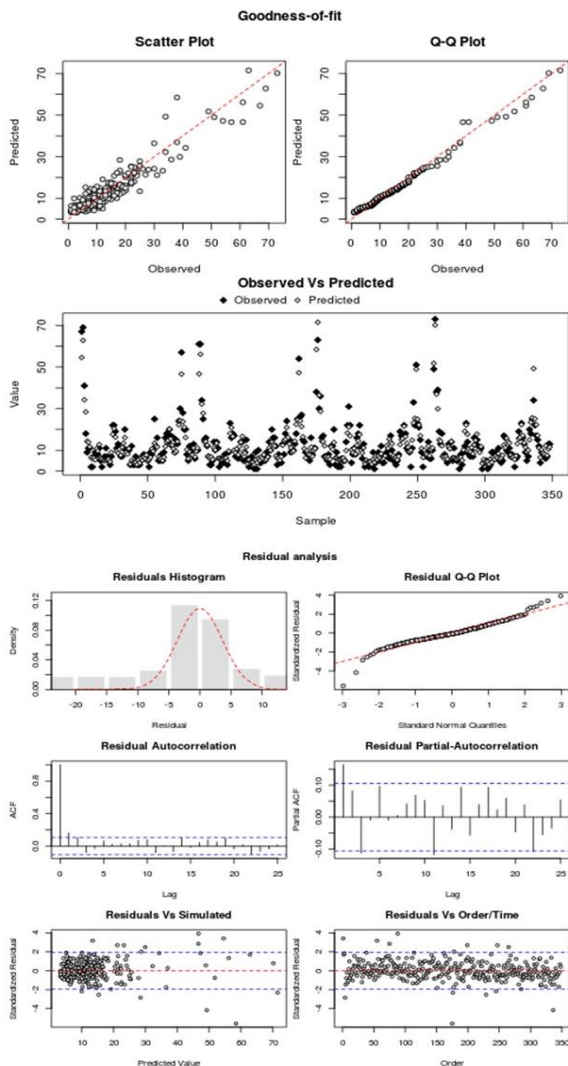


(c) NACM

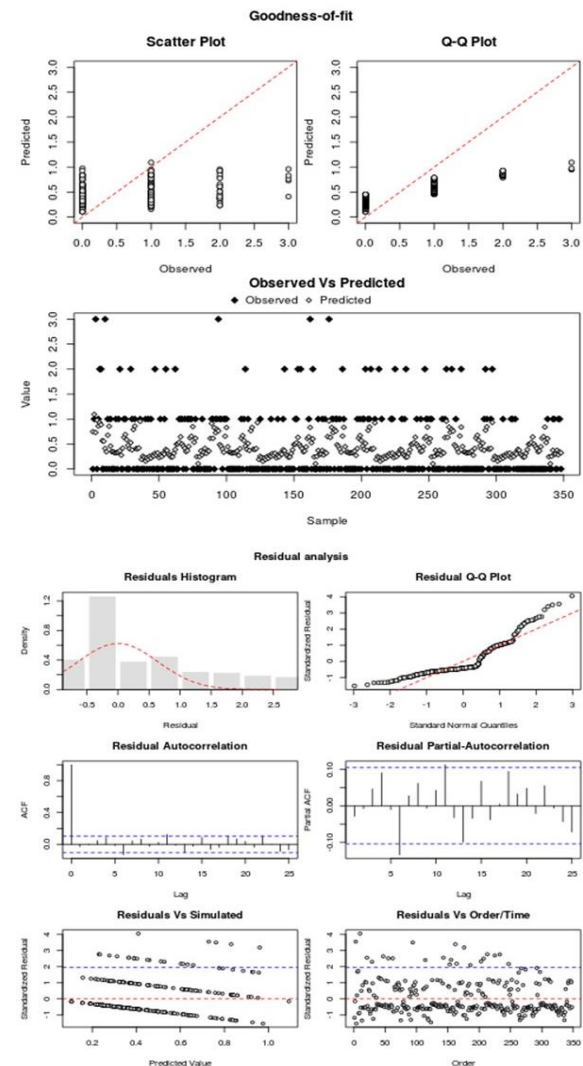
Figura C. 25– Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PN\_3,5km\_2015\_2018 (MVPLN – backward)



**(a) NASV**

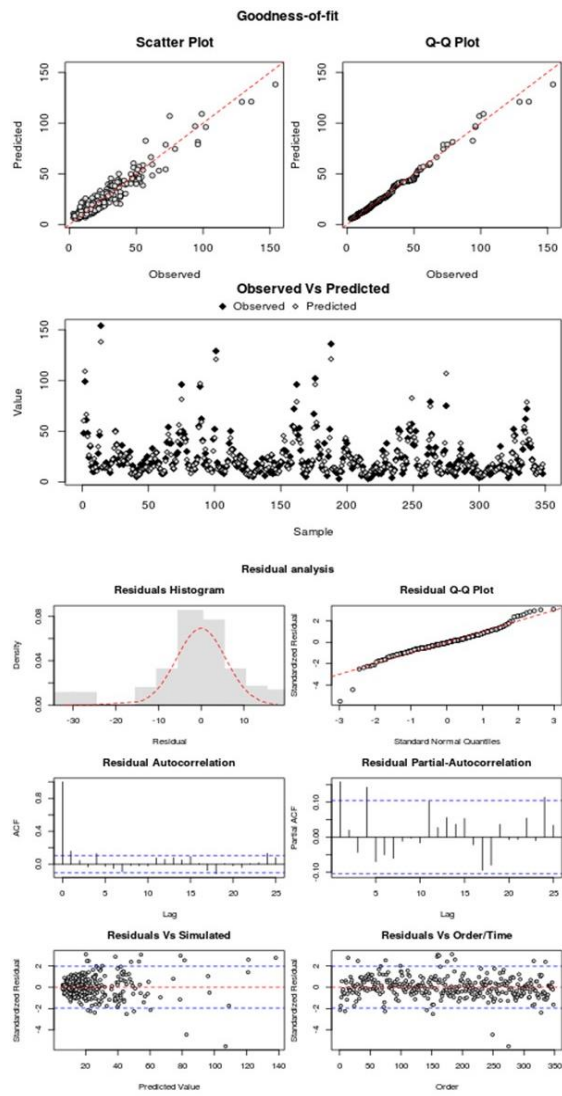


**(b) NACV**

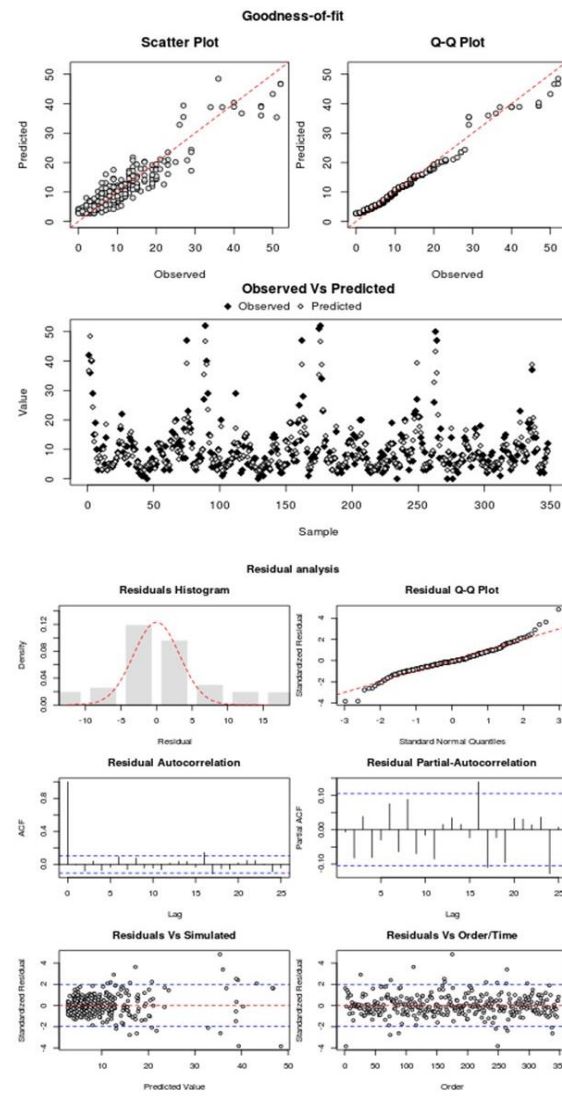


**(c) NACM**

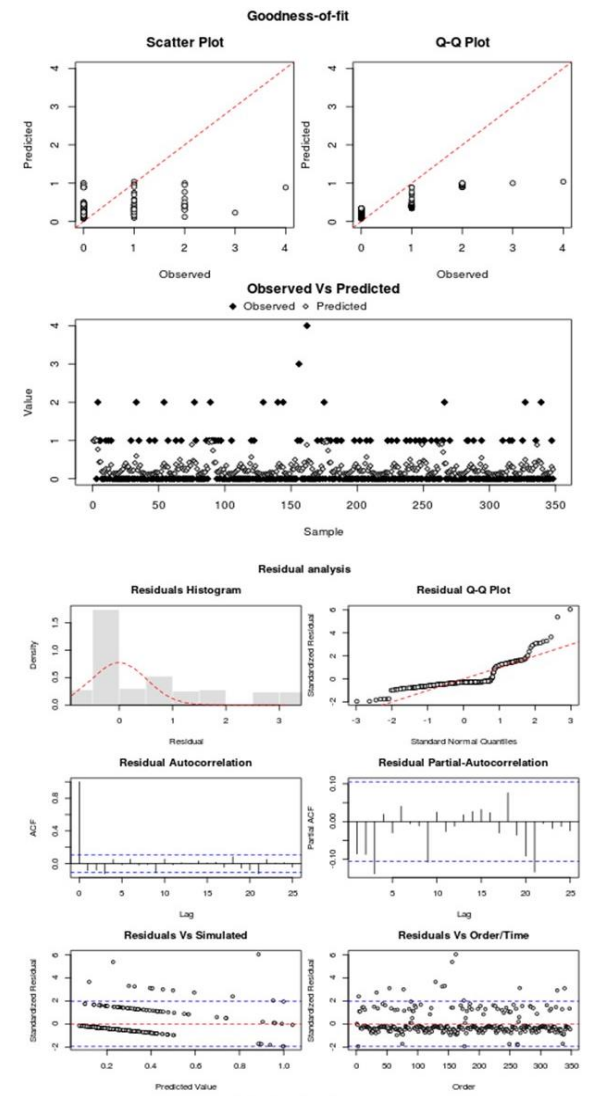
**Figura C. 26 – Qualidade de ajuste (goodness-of-fit) e análise de resíduos para PS\_4km\_2011\_2014 (MVPLN – backward)**



(a) NASV



(b) NACV



(c) NACM

Figura C. 27 – Qualidade de ajuste (*goodness-of-fit*) e análise de resíduos para PS\_4km\_2015\_2018 (MVPLN – backward)