



Universidade do Estado do Rio de Janeiro

Centro de Ciência e Tecnologia

Faculdade de Engenharia

Fabiana Leão Chaves

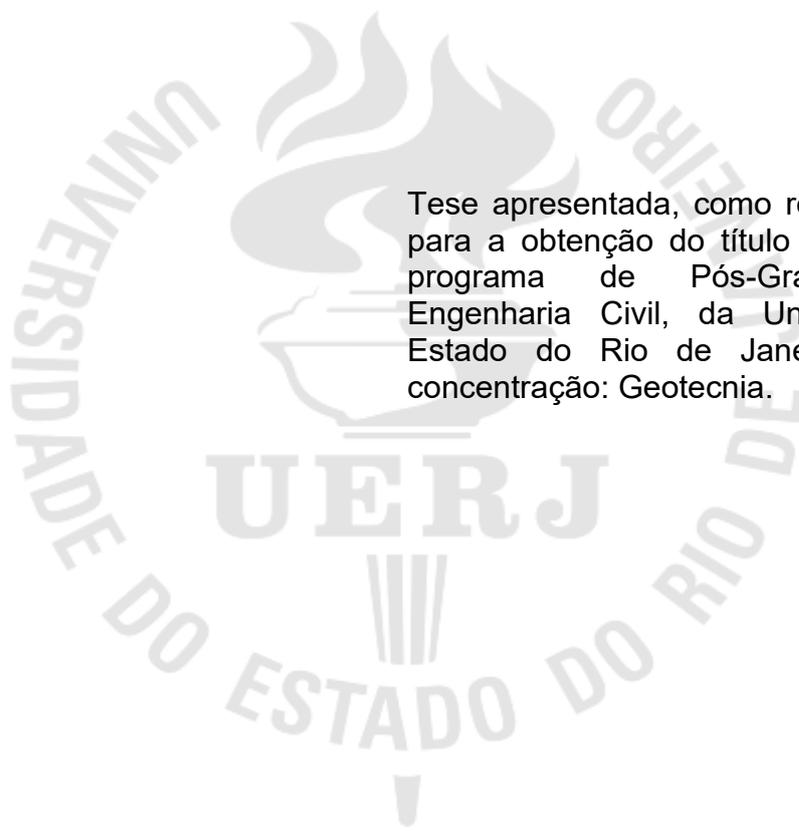
**Uso de modelos de aprendizado de máquina para previsão de
movimentos de massa na Cidade do Rio de Janeiro**

Rio de Janeiro

2024

Fabiana Leão Chaves

Uso de modelos de aprendizado de máquina para previsão de movimentos de massa na Cidade do Rio de Janeiro



Tese apresentada, como requisito parcial para a obtenção do título de Doutor, ao programa de Pós-Graduação em Engenharia Civil, da Universidade do Estado do Rio de Janeiro. Área de concentração: Geotecnia.

Orientadores: Prof^a. D.Sc Denise Maria Soares Gerscovich
Prof. D.Sc. Harold Dias de Mello Junior

Rio de Janeiro

2024

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

C512 Chaves, Fabiana Leão.
Uso de modelos de aprendizado de máquina para previsão de movimentos de massa na Cidade do Rio de Janeiro / Fabiana Leão Chaves. – 2024.
262 f.

Orientadores: Denise Maria Soares Gerscovich, Harold Dias de Mello Junior.

Tese (Doutorado) - Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia civil - Teses. 2. Mecânica do solo - Previsão - Teses. 3. Chuvas - Teses. 4. Solos - Inundação - Teses. 5. Aprendizado do computador - Teses. I. Gerscovich, Denise Maria Soares. II. Mello Junior, Harold Dias de. III. Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia. IV. Título.

CDU 624.131.52

Bibliotecária: Júlia Vieira – CRB7/6022

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte.



Assinatura

25 de novembro de 2024

Data

Fabiana Leão Chaves

Uso de modelos de aprendizado de máquina para previsão de movimentos de massa na Cidade do Rio de Janeiro

Tese apresentada, como requisito parcial para a obtenção do título de Doutor, ao programa de Pós-Graduação em Engenharia Civil, da Universidade do Estado do Rio de Janeiro. Área de concentração: Geotecnia.

Aprovado em: 25 de julho de 2024.

Banca Examinadora:



Profa. Dra. Denise Maria Soares Gerscovich – Presidente/ Orientadora
Faculdade de Engenharia – UERJ



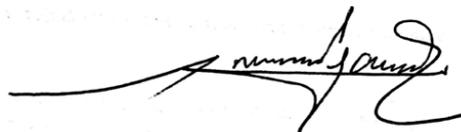
Prof. Dr. Harold Dias de Mello Junior - Orientador
Universidade do Estado do Rio de Janeiro – UERJ



Prof. Dr. Roberto Quental Coutinho
Universidade Federal de Pernambuco – UFPE



Prof. Dr. Marcos Massao Futai
Universidade de São Paulo – USP



Prof. Dr. Marcus Peigas Pacheco
Faculdade de Engenharia – UERJ



Profa. Dra. Karla Tereza Figueiredo Leite

Universidade do Estado do Rio de Janeiro – UERJ



Profa. Dra. Bernadete Ragoni Danziger

Faculdade de Engenharia – UERJ



Profa. Dra. Luciana Conceição Dias Campos

Universidade Federal de Juiz de Fora – UFJF

Rio de Janeiro

2024

DEDICATÓRIA

Aos meus avós Dulce, Manoel e João que, em sua simplicidade e humildade, deixaram lições para toda a vida.

A tia Cida pelas conversas e pensamentos, principalmente quando eu era criança, sobre a importância do conhecimento.

AGRADECIMENTOS

São tantas as pessoas que de uma forma ou de outra contribuíram durante a jornada até aqui, que sou incapaz de lembrar de todas, ou de escrever seus nomes. Mas vez ou outra, em algum momento da vida, do dia, das circunstâncias, elas renascem na memória. A vocês, que sei quem são, minha gratidão.

A minha mãe, que mesmo distante dedica sua fé ao que chama de realização dos meus sonhos. Suas orações e amor são bem-vindos e foram necessários em todos os momentos.

A tia Ângela que há 20 anos atrás me acolheu. Obrigada por acreditar comigo.

Às pessoas que, muitas vezes sem perceber suas magnitudes, transmitem ondas que movimentam e inspiram aqueles a seu redor, tal como a Prof^ª Denise e o Prof. Marcus. Obrigada pela companhia, por todos estes anos, são quase 15 anos de jornada desde que nos encontramos pela primeira vez. Há encontros que mudam nossa vida. Sou grata por ter tido a oportunidade de tê-los como meus professores, meus orientadores e hoje meus amigos.

Ao Prof. Harold Mello pela parceria neste vasto mundo, que considero novo, de aprendizado de máquina e linguagem de programação.

A Fabio Cerbino, pela companhia de todas as horas, pela força transmitida, por acreditar que eu conseguiria e por dizer isto muitas vezes, incansavelmente. Você também vai conseguir, é magnífico.

À minha família, pai, irmãos e irmã, que incentivam e expressam seu orgulho com minhas vitórias. Sinto saudade de estar mais com vocês.

A UERJ, instituição que eu amo, que mudou minha vida, e a todos que fazem parte dela, que direta ou indiretamente contribuem com a realização de sonhos e construção de um futuro melhor, de um Brasil melhor.

Por último, mas não menos importante, a Deus. Onde quer que esteja e quem quer que seja, por, de alguma forma, fazer brotar na cabeça de uma garotinha de 6 anos que ela seria engenheira e colocar sonhos que, por bastante tempo, pareceram impossíveis. Alguns ainda parecem, mas cada coisa em seu tempo.

Quando eu era criança me apresentaram a fé.
Antes era somente medo. Medo congelante.
Quando ele conheceu a fé, mudou de fase.
Às vezes medo, às vezes coragem.

Fabiana Leão Chaves

RESUMO

CHAVES, Fabiana L. **Uso de modelos de aprendizado de máquina para previsão de movimentos de massa na Cidade do Rio de Janeiro**. 2024. 262 f. Tese (Doutorado em Engenharia Civil) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2024.

Movimentos de massa são fenômenos recorrentes em regiões montanhosas e sua taxa de ocorrência se intensifica em períodos chuvosos. Modelos de correlação entre precipitação e movimentos de massa são fundamentados na teoria de tensões efetivas e têm sido utilizados como ferramentas de mitigação de efeitos catastróficos, que movimentos de massa podem causar. Tais modelos possuem, predominantemente, natureza empírica e, independentemente de sua tipologia, são desenvolvidos a partir de banco de dados. Atualmente na cidade do Rio de Janeiro, está em operação o Sistema Alerta Rio que é baseado em modelo gráfico e adota acumuladas de precipitação para acionamento de sirenes e evacuação de áreas de risco. Nesta tese, com objetivo de apresentar alternativa ou complemento ao modelo gráfico em operação e tomando-se os bancos de dados de movimentos de massa e de precipitação, do período de 2009 a 2015 da cidade do Rio de Janeiro, foram construídos classificadores a partir dos modelos Floresta Aleatória (Random Forest - RF), Máquina de Vetores-Suporte (Support Vector Machine - SVM) e Perceptron Multicamadas (Multi-Layer Perceptron - MLP). Cada modelo foi treinado, validado e testado considerando-se o período de 96h de chuvas. A adoção deste intervalo temporal permite a incorporação da chuva precipitada na data (24h) de ocorrência do movimento de massa e, também, da chuva antecedente que se precipitou nas 72h anteriores à data de ocorrência do movimento de massa. Concernente aos modelos desenvolvidos, o classificador RF apresentou melhores resultados do que os classificadores SVM ou MLP. Sendo assim, pode-se dizer que o modelo Floresta Aleatória – RF sinaliza melhor desempenho, embora, de modo geral, os erros de validação e de teste dos modelos indiquem que eles não atingiram o desempenho desejado. Ademais, o estudo realizado nesta pesquisa evidencia a importância de bancos de dados disponíveis para construção de modelos, principalmente daqueles fundamentados em técnicas de aprendizado de máquina, uma vez que a evolução de desempenho de tais modelos está diretamente relacionada à quantidade e à qualidade de dados para realização de treinamento, validação e teste. No caso em questão, a existência de mais dados relacionados a movimentos de massa poderia resultar em melhor desempenho e conseqüentemente em maior confiança do modelo.

Palavras-chave: Movimento de Massa; Chuva; Aprendizado de Máquina; Aprendizado Supervisionado; Modelos de Classificação.

ABSTRACT

CHAVES, Fabiana L. **Predicting landslides from machine learning models. A case in the city of Rio de Janeiro.** 2024. 262 f. Tese (Doutorado em Engenharia Civil) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2024.

Landslides are recurring phenomena in mountainous regions, and their rate of occurrence intensifies during rainy periods. Correlation models of precipitation vs. landslides are based on the Theory of Effective Stress and have been playing a role as tools to mitigate the catastrophic effects of landslide occurrences. Such models are predominantly empirical, and, regardless of their typology, they are developed from a database. Currently, in the city of Rio de Janeiro, the Alerta Rio System is based on a graphic correlation model and uses the rate of precipitation as a reference to trigger sirens and evacuate risky areas. The main objective of this research is to propose a classifier as an alternative or as a complement to the present model in operation by adopting the databases of landslides and precipitation from the period 2009 to 2015 in the city of Rio de Janeiro. The best classifier model will be chosen among three distinct models built by three different algorithms: Random Forest (RF), Support Vector Machine (SVM) and Multi-Layer Perceptron (MLP). Each model is trained, validated and tested considering a period of 96 hours, which allows the incorporation of the precipitation of the date (24 hours) of the landslide occurrence and also the preceding rain that precipitated within 72 hours prior to the date of the landslide occurrence. Regarding the models developed, the RF classifier presented better results than the SVM or MLP classifiers. Therefore, it can be said that the Random Forest (RF) shows better performance, although, in general, the validation and testing errors of the models indicate that they did not achieve the intended performance. Furthermore, the study carried out in this research highlights the importance of the database available for building models based on machine learning techniques, mainly due to the fact that the performance evolution of such models is related to the quantity and quality of data for carrying out training, validation and testing. In the case in question, the existence of more data related to landslides could result in better performance and, consequently, greater confidence in the model.

Keywords: Landslide; Rainfall; Machine Learning; Supervised Learning; Classification Models.

LISTA DE FIGURAS

| | |
|---|----|
| Figura 1 - Região Serrana do Rio de Janeiro - 2011 (CPRM, 2013)..... | 30 |
| Figura 2 - Condição de ruptura por movimentos de massa (Modificado de Gerscovich, 2012)..... | 32 |
| Figura 3 – Matriz de Confusão – Classificação Binária..... | 38 |
| Figura 4 – Distribuição geográfica (Peruccacci <i>et al.</i> , 2017)..... | 40 |
| Figura 5 – Limiar Pluviométrico em escala logarítmica – Itália (Peruccacci <i>et al.</i> , 2017)..... | 40 |
| Figura 6 – Fluxograma do sistema de alerta italiano (a) precipitação e entrada para armazenamento de dados, (b) processamento e análise de dados, e (c) produção e entrega das previsões. (Modificado de Rossi <i>et al.</i> , 2012)..... | 41 |
| Figura 7 – Limiar Pluviométrico – Sistema Alerta Japão..... | 43 |
| Figura 8 – Transmissão de informações de alerta. AMJ - Agência de Meteorologia do Japão (Modificado de Osanai <i>et al.</i> , 2010)..... | 43 |
| Figura 9 – Limiar pluviométrico– Hong Kong..... | 46 |
| Figura 10 – Pluviômetros - Sistema Alerta Rio (Calvello <i>et al.</i> , 2015)..... | 47 |
| Figura 11 – Zonas de Alerta: Sistema Alerta Rio (Calvello <i>et al.</i> , 2015)..... | 48 |
| Figura 12 – Limiares de chuva intensidade-duração (Modificado de Berti <i>et al.</i> , 2012)..... | 58 |
| Figura 13 –Análise Bayesiana – Idukki - Índia (Modificado de Treesa <i>et al.</i> , 2021) .. | 60 |
| Figura 14 – Limiares de Severidade de Eventos (Treesa <i>et al.</i> , 2021)..... | 61 |
| Figura 15 – Grupos de “Machine Learning”(Modificado de Machado <i>et al.</i> , 2020).... | 63 |
| Figura 16 – Fluxo - Construção de Modelo (Modificado de Scikit-Learn,2007)..... | 64 |
| Figura 17 – Validação Cruzada (Modificado de Scikit-Learn,2007)..... | 68 |
| Figura 18 – Sobreajuste e Subajuste - Classificação (Modificado de Mathworks, 2023)..... | 70 |
| Figura 19 – Hiperparâmetros (Modificado de Arnold <i>et al.</i> , 2023)..... | 71 |
| Figura 20 – Floresta Aleatória - Aprendizado Conjunto (Modificado de Yeon, 2020) | 72 |
| Figura 21 – Floresta Aleatória - Aprendizado Conjunto (Modificado de Yeon, 2020) | 73 |
| Figura 22 – Floresta Aleatória Genérica (Modificado de Wood, 2020)..... | 74 |
| Figura 23 – Método SVM e não Linearidade (Modificado de Rhys, 2020)..... | 75 |
| Figura 24 –SVM – Kernel - Funções (Modificado de Scikit-Learn,2007)..... | 76 |

| | |
|--|-----|
| Figura 25 – Rede Neural (Modificado de Wilber, 2023) | 77 |
| Figura 26 – Perceptron Multicamadas (Modificado de Scikit-Learn,2007) | 77 |
| Figura 27 – Matriz de Confusão – Classificação Binária | 80 |
| Figura 28 – Modelo Curva ROC (Modificado de Brownlee, 2020)..... | 82 |
| Figura 29 – Distribuição de Classes Binárias – Exemplo (Modificado de Wilber, 2022) | 84 |
| Figura 30 – Ilustração de Distribuição de Classes Binárias | 85 |
| Figura 31 – Curva ROC (Modificado de Wilber, 2022)..... | 85 |
| Figura 32 – Fluxograma.(Modificado de Pham <i>et al.</i> , 2018)..... | 92 |
| Figura 33 – Validação com a AUROC (Modificado de Pham <i>et al.</i> , 2018)..... | 93 |
| Figura 34 – Mapa de Suscetibilidade (Pham <i>et al.</i> , 2018)..... | 94 |
| Figura 35 – Fluxo de Desenvolvimento e Resultados dos Modelos | 97 |
| Figura 36 – Macrorregiões de Drenagem da Cidade do Rio de Janeiro, Drenagem e Manejo de Águas Pluviais Urbanas (Fundação Instituto das Águas, 2015) | 98 |
| Figura 37 – Mapa de suscetibilidade a movimentos de massa da cidade do Rio de Janeiro - Áreas em amarelo são de média suscetibilidade e áreas em vermelho são de alta suscetibilidade - Geo-Rio (2015) | 99 |
| Figura 38 – Movimento de Massa no Maciço da Tijuca | 100 |
| Figura 39 – Movimento de Massa - Área de estudo | 101 |
| Figura 40 – Polígonos de Thiessen e Movimento de Massa | 101 |
| Figura 41 – Dispersão Fatores Severidade e Distribuição (Chaves,2016)..... | 106 |
| Figura 42 – Movimentos de Massa – Estações Pluviométricas..... | 107 |
| Figura 43 – Movimento de Massa - Estação Média | 111 |
| Figura 44 – Histogramas - Acumulada Diária - Estações | 114 |
| Figura 45 – Dispersões - Acumulada Diária e Duração - Estações..... | 115 |
| Figura 46 – Diagrama de Caixa – Modelo Informativo | 117 |
| Figura 47 – Diagrama de Caixa – Estações Pluviométricas..... | 118 |
| Figura 48 – Histograma - Acumulada Diária – Estação Média | 120 |
| Figura 49 – Dispersão - Acumulada Diária e Duração – Estação Média..... | 120 |
| Figura 50 – Diagrama de Caixa – Estações pluviométricas e Estação Média | 122 |
| Figura 51 – Histograma – Movimentos de Massa – Estações..... | 124 |
| Figura 52 – Dispersão – Movimentos de Massa - Estações | 124 |
| Figura 53 – Diagrama de Caixa – Estações pluviométricas e movimentos de massa | 126 |

| | |
|--|-----|
| Figura 54 – Histograma – Movimentos de Massa 1º Intervalo – Estação Média..... | 128 |
| Figura 55 – Dispersão Acumulada Diária e Duração – Movimentos de Massa –.... | 128 |
| Figura 56 – Diagrama de Caixa – Estação Média e Movimentos de Massa | 129 |
| Figura 57 – Diagrama de Caixa – Conjuntos de movimentos de massa | 130 |
| Figura 58 – Dispersão Acumulada Diária e Duração – Estação Tijuca | 132 |
| Figura 59 – Probabilidades a Posteriori e do Alerta-Rio - Estações 2009 a 2015... | 134 |
| Figura 60 – Histograma 3D – Estação Média 2009 a 2015..... | 138 |
| Figura 61 – Probabilidades a Posteriori e do Alerta-Rio - Estação Media 2009 a 2015 | 140 |
| Figura 62 – Bloco de Eventos Pluviométricos – MP01..... | 143 |
| Figura 63 – Bloco de Eventos Pluviométricos – MP02..... | 144 |
| Figura 64 – Procedimento Metodológico..... | 151 |
| Figura 65 – Floresta Aleatória (MP01): Distribuição Probabilística - Limiar Padrão e Limiar Otimizado - Teste | 163 |
| Figura 66 – Floresta Aleatória (MP01): Matriz de Confusão - Limiar Padrão - Teste | 164 |
| Figura 67 – Floresta Aleatória (MP01): Matriz de Confusão - Limiar Otimizado - Teste | 165 |
| Figura 68 – Floresta Aleatória (MP02): Matriz de Confusão - Limiar Padrão - Teste | 169 |
| Figura 69 – Floresta Aleatória (MP02): Matriz de Confusão - Limiar Otimizado - Teste | 170 |
| Figura 70 – Máquina de Vetores-Suporte (MP01): Matriz de Confusão - Limiar Padrão - Teste | 175 |
| Figura 71 – Máquina de Vetores-Suporte (MP01): Matriz de Confusão - Limiar Otimizado - Teste | 176 |
| Figura 72 – Máquina de Vetores-Suporte (MP02): Matriz de Confusão - Limiar Padrão - Teste | 181 |
| Figura 73 – Máquina de Vetores-Suporte (MP02): Matriz de Confusão - Limiar Otimizado - Teste | 182 |
| Figura 74 – Perceptron Multicamadas (MP01): Matriz de Confusão - Limiar Padrão - Teste | 187 |
| Figura 75 – Perceptron Multicamadas (MP01): Matriz de Confusão - Limiar Otimizado - Teste | 188 |

| | |
|---|-----|
| Figura 76 – Perceptron Multicamadas (MP02): Matriz de Confusão - Limiar Padrão - Teste | 193 |
| Figura 77 – Perceptron Multicamadas (MP02): Matriz de Confusão - Limiar Otimizado - Teste | 194 |
| Figura 78 – Floresta Aleatória – Classes Desbalanceadas – Limiar Padrão - MP01 e MP02..... | 196 |
| Figura 79 – Floresta Aleatória – Classes Balanceadas – Limiar Padrão - MP01 e MP02 | 196 |
| Figura 80 – Floresta Aleatória – Classes Balanceadas – Limiar Otimizado - MP01 e MP02..... | 196 |
| Figura 81 – Máquina de Vetores Suporte – Classes Desbalanceadas – Limiar Padrão - MP01 e MP02 | 198 |
| Figura 82 – Máquina de Vetores Suporte – Classes Balanceadas – Limiar Padrão - MP01 e MP02..... | 198 |
| Figura 83 – Máquina de Vetores Suporte – Classes Balanceadas – Limiar Otimizado - MP01 e MP02 | 198 |
| Figura 84 – Perceptron Multicamadas – Classe Desbalanceadas – Limiar Padrão - MP01 e MP02..... | 200 |
| Figura 85 – Perceptron Multicamadas – Classe Balanceadas – Limiar Padrão - MP01 e MP02..... | 200 |
| Figura 86 – Perceptron Multicamadas – Classe Balanceadas – Limiar Otimizado - MP01 e MP02..... | 200 |
| Figura 87 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Desbalanceadas -- MP01 | 203 |
| Figura 88 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Balanceadas -- MP01 | 203 |
| Figura 89 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Balanceadas -- MP01 | 203 |
| Figura 90 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Desbalanceadas -- MP02 | 206 |
| Figura 91 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Balanceadas -- MP02 | 206 |
| Figura 92 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Balanceadas -- MP02 | 206 |

| | |
|---|-----|
| Figura 93 – Floresta Aleatória (MP01): Exemplo de Aplicação do Modelo | 208 |
| Figura 94 – Estrutura de Aplicação do Modelo..... | 212 |
| Figura 95 – Estrutura para Aplicação do Modelo – Intervalo Futuro | 212 |

LISTA DE TABELAS

| | |
|--|-----|
| Tabela 1 – Classificação dos fatores deflagradores dos movimentos de massa (Modificada de Varnes 1978) | 33 |
| Tabela 2. Classificação Principal - Movimentos de massa (Cruden e Varnes, 1996) | 34 |
| Tabela 3. Classificação Complementar – Velocidade dos Movimentos de massa | 34 |
| Tabela 4. Padrões de Movimento de Massa (Santos, 2004)..... | 35 |
| Tabela 5. Versão atualizada da Classificação de Varnes (Modificado de Hungr et al, 2014) | 36 |
| Tabela 6. Níveis de Alerta - Japão (Modificado de Nippon, 2019) | 44 |
| Tabela 7. Níveis de Alerta – Hong Kong (Modificado de Kong <i>et al.</i> , 2020)..... | 47 |
| Tabela 8 – Tipologias para a classificação das ocorrências (GEO-RIO, 2010)..... | 48 |
| Tabela 9 - Critérios operacionais do Sistema Alerta-Rio | 49 |
| Tabela 10. Resumo de propostas de Limiares Pluviométricos (Modificado de Chaves. 2016) | 55 |
| Tabela 11. Modelos Probabilísticos - Teorema de Bayes | 62 |
| Tabela 12. Modelo - Estruturação de Dados | 65 |
| Tabela 13. Métricas de desempenho – Taxa de erro | 78 |
| Tabela 14. Função log do erro – Exemplo de Referencial Máximo | 79 |
| Tabela 15. Métricas de desempenho – Matriz de confusão | 81 |
| Tabela 16. Métricas de desempenho combinadas | 82 |
| Tabela 17. Técnicas de Aprendizado de Máquina em Geotecnia/Geologia | 90 |
| Tabela 18. Diretrizes da Análise | 97 |
| Tabela 19 – Critérios - Movimentos de Massa – Estação Pluviométrica – Etapa 1. | 105 |
| Tabela 20 – Critérios - Movimentos de Massa – Estação Pluviométrica – Etapa 2. | 107 |
| Tabela 21 – Estações Pluviométricas – Movimentos de Massa 2009 a 2015 | 108 |
| Tabela 22 – Critérios - Movimentos de Massa – Estação Média – Etapa 1 | 110 |
| Tabela 23 – Critérios - Movimentos de Massa – Estação Média – Etapa 2 | 110 |
| Tabela 24 – Estação Média – Movimentos de Massa 2009 a 2015 | 111 |
| Tabela 25 – Acumuladas Diárias (24h) – Estações - 2009 a 2015..... | 113 |
| Tabela 26 – Medidas de Tendência Central e de Variação – Estações - Acumulada Diária | 116 |
| Tabela 27 – Medidas de Posição – Acumulada Diária - Estações - 2009 a 2015 ... | 118 |

| | |
|--|-----|
| Tabela 28 – Acumuladas Diárias(24h) - Estação Média - 2009 a 2015 | 120 |
| Tabela 29 – Medidas de Tendência Central e de Variação – Estação Média | 121 |
| Tabela 30 – Medidas de Posição – Acumulada Diária - Estação Média - 2009 a 2015 | 122 |
| Tabela 31 –Tendência Central e Variação – Acumulada Diária de Movimentos - Estações..... | 123 |
| Tabela 32 – Medidas de Posição – Movimentos de Massa | 125 |
| Tabela 33 – Tendência Central e de Variação – Movimentos – Estação Média | 128 |
| Tabela 34 – Medidas de Posição – Movimentos de Massa – Estação Média | 131 |
| Tabela 35 – Precipitação da Estação Tijuca- 2009 a 2015 | 132 |
| Tabela 36 – Probabilidade a Posteriori – Compilação Estações | 135 |
| Tabela 37 – Precipitação da Estação Média- 2009 a 2015 | 138 |
| Tabela 38. Eventos Precipitação com Movimentos de Massa – MP01 | 147 |
| Tabela 39. Eventos Precipitação com Movimentos de Massa – MP02 | 148 |
| Tabela 40. Segregação de Amostras de Teste | 153 |
| Tabela 41. Segregação de Amostras de Treinamento e Validação | 154 |
| Tabela 42. Floresta Aleatória – Hiperparâmetros | 154 |
| Tabela 43. Máquina de Vetores-Suporte – Hiperparâmetros | 154 |
| Tabela 44. Perceptron Multicamadas – Hiperparâmetros | 154 |
| Tabela 45. Floresta Aleatória – MP01: Hiperparâmetros, Métricas e Limiares | 159 |
| Tabela 46. Floresta Aleatória – MP01: Classes Desbalanceadas e Limiar Padrão. | 160 |
| Tabela 47. Floresta Aleatória – MP01: Classes Balanceadas e Limiar Padrão..... | 161 |
| Tabela 48. Floresta Aleatória – MP01: Classes Balanceadas e Limiar Otimizado .. | 164 |
| Tabela 49. Floresta Aleatória – MP02: Hiperparâmetros, Métricas e Limiares | 167 |
| Tabela 50. Floresta Aleatória – MP02: Classes Balanceadas e Limiar Padrão..... | 168 |
| Tabela 51. Floresta Aleatória – MP02: Classes Balanceadas e Limiar Otimizado .. | 170 |
| Tabela 52. Máquina de Vetores-Suporte – MP01: Hiperparâmetros, Métricas e Limiares..... | 173 |
| Tabela 53. Máquina de Vetores-Suporte – MP01: Classes Balanceadas e Limiar Padrão..... | 174 |
| Tabela 54. Máquina de Vetores-Suporte – MP01: Classes Balanceadas e Limiar Otimizado | 176 |
| Tabela 55. Máquina de Vetores-Suporte – MP02: Hiperparâmetros, Métricas e Limiares..... | 179 |

| | |
|--|-----|
| Tabela 56. Máquina de Vetores-Suporte – MP02: Classes Balanceadas e Limiar Padrão..... | 180 |
| Tabela 57. Máquina de Vetores-Suporte – MP02: Classes Balanceadas e Limiar Otimizado | 182 |
| Tabela 58. Perceptron Multicamadas – MP01: Hiperparâmetros, Métricas e Limiares | 185 |
| Tabela 59. Perceptron Multicamadas – MP01: Classes Balanceadas e Limiar Padrão | 186 |
| Tabela 60. Perceptron Multicamadas – MP01: Classes Balanceadas e Limiar Otimizado | 188 |
| Tabela 61. Perceptron Multicamadas – MP02: Hiperparâmetros, Métricas e Limiares | 191 |
| Tabela 62. Perceptron Multicamadas – MP02: Classes Balanceadas e Limiar Padrão | 192 |
| Tabela 63. Perceptron Multicamadas – MP02: Classes Balanceadas e Limiar Otimizado | 194 |
| Tabela 64. Exemplo de Classificação – Dados Entrada de Estação Média | 209 |
| Tabela 65. Exemplo – Resultado do Modelo Classificador | 211 |
| Tabela 66. Aplicação do Modelo - Dados de Entrada – Intervalo Futuro | 213 |
| Tabela 67 – Dados de Entrada Classes (0) e (1) – MP01 | 237 |
| Tabela 68 – Dados de Entrada Classes (0) e (1) – MP02..... | 246 |
| Tabela 69 – Precipitação da Estação Alto da Boa Vista- 2009 a 2015 | 251 |
| Tabela 70 – Precipitação da Estação Grajaú - 2009 a 2015 | 251 |
| Tabela 71 – Precipitação da Estação Laranjeiras - 2009 a 2015 | 252 |
| Tabela 72 – Precipitação da Estação Santa Teresa - 2009 a 2015 | 252 |
| Tabela 73. Floresta Aleatória – MP02: Classes Desbalanceadas e Limiar Padrão..... | 253 |
| Tabela 74. Máquina de Vetores-Suporte – MP01: Classes Desbalanceadas e Limiar Padrão..... | 255 |
| Tabela 75. Máquina de Vetores-Suporte – MP02: Classes Desbalanceadas e Limiar Padrão..... | 257 |
| Tabela 76. Perceptron Multicamadas – MP01: Classes Desbalanceadas e Limiar Padrão..... | 259 |
| Tabela 77. Perceptron Multicamadas – MP02: Classes Desbalanceadas e Limiar Padrão..... | 261 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|----------|--|
| AMJ | Agência de Meteorologia do Japão |
| ANN | Redes Neurais Artificiais |
| ANN-RBF | Redes Neurais com Função de Ativação de Base Radial (<i>Radial Basis Function Neural Network</i>) |
| AODE | Estimador Médio de uma Dependência (<i>Averaged One-Dependence Estimators</i>). |
| AUROC | Área Sob a Curva Característica de Operação do Receptor (<i>Area Under Receiver Operator Characteristic Curve</i>) |
| CEMADEM | Centro Nacional de Monitoramento e Alertas de Desastres Naturais |
| CPRM | Companhia de Pesquisa de Recursos Minerais |
| DESC | Department of Erosion and Sediment Control |
| DRM-RJ | Departamento de Recursos Minerais do Rio de Janeiro |
| ETR | Estações Totais Robotizadas |
| FN | Falso-Negativo |
| FP | Falso-Positivo |
| GES DISC | Goddard Earth Science Data and Information Services Center |
| INMET | Instituto Nacional de Meteorologia |
| INPE | Instituto Nacional de Pesquisas Espaciais |
| LR | Regressão Logística (<i>Logistic Regression</i>) |
| MATLAB | Plataforma de Programação e Computação Numérica |
| MDR | Ministério de Desenvolvimento Regional |
| MLP | Perceptron Multicamadas (<i>Multi-layer Perceptron</i>) |
| NB | Classificador Fundamentado no Teorema de Bayes (<i>Naive Bayes</i>) |
| PCD GEO | Plataforma de Coleta de Dados Geotécnicos |

| | |
|---------|---|
| PTE | Princípio das Tensões Efetivas |
| QGIS | Sistema de Informação Geográfica Livre e Aberto |
| RF | Floresta Aleatória (Random Forest) |
| RNA | Rede Neural Artificial |
| ROC | Curva Característica de Operação do Receptor (<i>Receiver Operator Characteristic Curve</i>) |
| SANF | Sistema Nacional de Alerta da Itália |
| SHETRAN | Système Hydrologique Europeia Transport |
| SIG | Sistemas de Informação Geográfica |
| SMOTE | Técnica de Geração de Amostras Sintéticas (<i>Synthetic Minority Over-sampling Technique</i>) |
| SVM | Máquina de Vetores-Suporte (<i>Support Vector Machine</i>) |
| VN | Verdadeiro-Negativo |
| VP | Verdadeiro-Positivo |

LISTA DE SÍMBOLOS

- F1 Equação de média harmônica entre precisão e sensibilidade
- GMédia Equação de média geométrica entre sensibilidade e especificidade

SUMÁRIO

| | |
|--|-----------|
| INTRODUÇÃO | 24 |
| Motivação | 24 |
| Objetivos | 26 |
| Descrição dos Capítulos | 26 |
| 1 RELAÇÃO CHUVA VS MOVIMENTO DE MASSA | 28 |
| 1.1 Movimentos de Massa | 29 |
| 1.1.1 Agentes e Causas | 30 |
| 1.1.2 Sistemas de Classificação | 33 |
| 1.2 Sistemas de Alerta..... | 37 |
| 1.2.1 Itália | 39 |
| 1.2.2 Japão..... | 42 |
| 1.2.3 Hong Kong..... | 45 |
| 1.2.4 Município do Rio de Janeiro | 47 |
| 1.2.4.1. Desempenho | 49 |
| 2 MÉTODOS DE ANÁLISE | 52 |
| 2.1 Modelos Gráficos - Limiares Pluviométricos | 54 |
| 2.2 Modelos Probabilísticos – Teorema de Bayes..... | 57 |
| 2.3 Técnicas de Aprendizado de Máquina..... | 62 |
| 2.3.1 Dados de Entrada | 64 |
| 2.3.2 Treinamento e Validação | 66 |
| 2.3.3 Teste..... | 69 |
| 2.4 Modelos Classificadores -Técnica de Aprendizado Supervisionado..... | 71 |
| 2.4.1 Algoritmos..... | 72 |
| 2.4.1.1. Floresta Aleatória - <i>Random Forest</i> | 72 |
| 2.4.1.2. Máquina de Vetores Suporte - <i>Support Vector Machine</i> | 74 |
| 2.4.1.3. Perceptron Multicamadas - <i>Multi-layer Perceptron</i> | 76 |
| 2.4.2 Métricas de Avaliação..... | 78 |
| 2.4.2.1. Limiar entre Classes | 83 |
| 2.4.3 Susceptibilidade a Movimentos de Massa | 88 |
| 2.4.3.1. Tratamento de Dados (Pham <i>et al.</i> , 2018)..... | 92 |
| 2.4.3.2. Treinamento e Validação (Pham <i>et al.</i> , 2018) | 93 |

| | |
|---|-----------|
| 2.4.3.3. Teste (Pham <i>et al.</i> , 2018) | 94 |
| 3 DESENVOLVIMENTO DO MODELO..... | 96 |
| 3.1 Coleta de Dados | 97 |
| 3.1.1 Área de Estudo | 98 |
| 3.1.2 Movimentos de Massa | 100 |
| 3.2 Pré-Processamento de Dados | 102 |
| 3.2.1 Estações Pluviométricas..... | 104 |
| 3.2.1.1. Etapa 1 – Critérios de Localização e de Data de Ocorrência | 104 |
| 3.2.1.2. Etapa 2 - Critérios Pluviométricos..... | 105 |
| 3.2.2 Estação Média | 109 |
| 3.2.2.1. Etapa 1 – Critérios de Localização e de Data de Ocorrência | 109 |
| 3.2.2.2. Etapa 2 - Critérios Pluviométricos..... | 110 |
| 3.3 Análises Estatísticas Preliminares | 112 |
| 3.3.1 Estatística Descritiva – Dados Pluviométricos | 112 |
| 3.3.1.1. Enfoque 1: Precipitação Diária - Estações Pluviométricas | 113 |
| 3.3.1.2. Enfoque 2: Precipitação Diária - Estação Média | 119 |
| 3.3.1.3. Enfoque 3: Precipitação Diária com Movimentos de Massa - Estações Pluviométricas | 122 |
| 3.3.1.4. Enfoque 4: Precipitação Diária com Movimentos de Massa - Estação Média 126 | |
| 3.3.2 Estatística Inferencial – Teorema de Bayes..... | 131 |
| 3.3.2.1. Estações Tijuca, Alto da Boa Vista, Grajaú, Laranjeiras e Santa Teresa ... | 131 |
| 3.3.2.2. Estação Média | 138 |
| 3.3.2.3. Análise Comparativa - Estação Média vs Estações Tijuca, Alto da Boa Vista, Grajaú, Laranjeiras e Santa Teresa | 140 |
| 3.4 Estruturação de Dados | 142 |
| 3.4.1 Modulação de Precipitação..... | 142 |
| 3.4.2 Dados Pluviométricos – Estação Média..... | 145 |
| 3.4.2.1. Amostras da Classe (1) – Precipitação com Movimentos de Massa | 146 |
| 3.4.2.2. Amostras da Classe (0) – Precipitação Sem Movimento de Massa | 149 |
| 3.5 Implementação do Modelo..... | 150 |
| 3.5.1 Segregação de Amostras | 152 |
| 3.5.2 Hiperparâmetros | 154 |
| 3.5.3 Métricas | 155 |

| | | |
|----------|---|------------|
| 4 | RESULTADOS | 156 |
| 4.1 | Modelos Floresta Aleatória (<i>Random Forest - RF</i>) | 156 |
| 4.1.1 | Modulação Temporal – MP01 | 156 |
| 4.1.1.1. | Classes Desbalanceadas | 160 |
| 4.1.1.2. | Classes Balanceadas | 161 |
| 4.1.2 | Modulação Temporal – MP02..... | 165 |
| 4.1.2.1. | Classes Balanceadas | 168 |
| 4.2 | Modelos Máquina de Vetores-Suporte (<i>Support Vector Machine - SVM</i>)..... | 171 |
| 4.2.1 | Modulação Temporal – MP01 | 171 |
| 4.2.1.1. | Classes Balanceadas | 174 |
| 4.2.2 | Modulação Temporal – MP02..... | 177 |
| 4.2.2.1. | Classes Balanceadas | 180 |
| 4.3 | Modelos Perceptron Multicamadas (<i>Multi-layer Perceptron - MLP</i>)..... | 183 |
| 4.3.1 | Modulação Temporal – MP01 | 183 |
| 4.3.1.1. | Classes Balanceadas | 186 |
| 4.3.2 | Modulação Temporal – MP02..... | 189 |
| 4.3.2.1. | Classes Balanceadas | 192 |
| 5 | COMPARAÇÃO DOS RESULTADOS E APLICAÇÃO DO MODELO | 195 |
| 5.1 | Modulação de Precipitação..... | 195 |
| 5.1.1 | Floresta Aleatória (<i>Random Forest - RF</i>)..... | 195 |
| 5.1.2 | Máquina de Vetores-Suporte (<i>Support Vector Machine - SVM</i>) | 197 |
| 5.1.3 | Perceptron Multicamadas (<i>Multi-layer Perceptron - MLP</i>) | 199 |
| 5.2 | Modelos Classificadores | 201 |
| 5.2.1 | Modulação de Precipitação MP01 | 201 |
| 5.2.2 | Modulação de Precipitação MP02 | 204 |
| 5.3 | Análise Comparativa dos Resultados | 207 |
| 5.4 | Aplicação Do Modelo | 207 |
| 5.4.1 | Estrutura de Utilização do Modelo | 207 |
| 5.4.2 | Utilização do Modelo com Previsão Meteorológica | 211 |
| 6 | CONSIDERAÇÕES FINAIS | 214 |
| 6.1 | Conclusões | 215 |
| 6.2 | Discussões | 217 |
| 6.3 | Sugestões Para Pesquisas Futuras..... | 219 |
| | REFERÊNCIAS | 221 |

| | |
|---|------------|
| APÊNDICE A – DADOS DE ENTRADA..... | 237 |
| (a) Modulação da Precipitação – MP01 | 237 |
| (b) Modulação da Precipitação – MP02 | 246 |
| APÊNDICE B – PRECIPITAÇÃO COM E SEM MOVIMENTOS DE MASSA..... | 251 |
| (a) Estações Pluviométricas..... | 251 |
| APÊNDICE C – RESULTADOS CLASSES DESBALANCEADAS | 253 |
| (a) Floresta Aleatória: Modulação Temporal – MP02..... | 253 |
| (b) Máquina de Vetores-Suporte: Modulação Temporal – MP01 | 255 |
| (c) Máquina de Vetores-Suporte: Modulação Temporal – MP02 | 257 |
| (d) Perceptron Multicamadas: Modulação Temporal – MP01 | 259 |
| (e) Perceptron Multicamadas: Modulação Temporal – MP02 | 261 |

INTRODUÇÃO

Movimentos de massa são processos dinâmicos que ocorrem, em sua maioria em encostas, em regiões montanhosas, e se caracterizam pelo desprendimento e movimento descendente de solo e/ou rocha. São fenômenos de origem natural ou antrópica que resultam em prejuízos aos meio biofísico e social, podendo ser considerados eventos de risco (Zuquette *et al.*, 1995; Sestini, 1999, apud Bispo *et al.*, 2011).

No Brasil, os desastres resultantes de movimentos de massa são frequentes, o que implica em recorrentes perdas socioeconômicas (Dias *et al.*, 2021, apud Coutinho, 2023). Segundo Montoya (2013), os maiores desastres registrados no Brasil são decorrentes de movimentos de massa, inundação e erosão. Estes eventos estão relacionados à interação de diferentes fatores endógenos, tais como tipo de solo, tipo de rocha ou forma do relevo, e fatores exógenos, variáveis climáticas, fatores antrópicos, entre outros (Coutinho, 2023; Bispo *et al.*, 2011).

Motivação

A cidade do Rio de Janeiro, segundo Ehrlich *et al.* (2021), apresenta, em função de suas características geológicas e topográficas, suscetibilidade à ocorrência de movimentos de massa, principalmente em períodos de precipitação.

Em março e abril de 2010, o Município do Rio de Janeiro registrou 527 ocorrências de movimento de massa. Em apenas 4 (quatro) dias choveu a magnitude de precipitação equivalente à média mensal histórica. Ao longo de 2010 foram registradas 627 ocorrências de movimento de massa, das quais 84% se concentraram em março e abril de 2010, sendo 76% no mês de abril e 8% no mês de março, conforme dados do relatório de movimentos de massa disponibilizado na página do Sistema Alerta Rio da Prefeitura do Rio de Janeiro.

Segundo o Departamento de Recursos Minerais do Rio de Janeiro (DRM-RJ), os movimentos de massa e inundações ocorridos na região serrana do Rio de Janeiro, durante os dias 11 e 12 de janeiro de 2011, são considerados o pior desastre brasileiro dos últimos tempos envolvendo encostas. A intensidade e volume das rupturas estão associados às precipitações antecedentes, ao uso e ocupação do solo, bem como às erosões fluviais e pluviais.

Ainda, no período de 11 a 12 de janeiro de 2011, o Instituto Nacional de Pesquisas Espaciais (INPE), apontou que a estação do Instituto Nacional de Meteorologia (INMET) registrou 166mm de chuva no município de Nova Friburgo, magnitude que representa mais de 70% do valor médio histórico de precipitação para o mês. (Montoya, 2013).

De acordo com a UNICAMP (2022), o desastre que assolou Petrópolis em fevereiro de 2022 está diretamente relacionado ao baixo investimento em infraestrutura para estabilização de encostas e às políticas públicas de ocupação do solo e sociais. As regiões mais suscetíveis a movimentos de massa e, também por inundações, vem sendo ocupadas desde 1950. Em 2022, a análise comparativa indicou que a área de ocupação das encostas triplicou de tamanho nos últimos 72 anos. O panorama irregular de ocupação de encostas não é exclusivo da região serrana, ele se repete pelas encostas da cidade do Rio de Janeiro, demais grandes cidades do Brasil e é também reflexo de fragilidade de políticas públicas sociais.

Neste contexto complexo e com vistas a mitigar os efeitos catastróficos, sistemas de alerta foram desenvolvidos e implantados em diversas cidades para gerenciamento da presença humana em áreas suscetíveis.

Na cidade do Rio de Janeiro, o Sistema Alerta Rio acompanha as previsões de precipitação e é nutrido por critérios geotécnicos da Fundação Geo-Rio, para fins de evacuação das áreas suscetíveis. Desta forma, os sistemas de evacuação passaram a atuar como instrumento necessário para orientação da parcela da sociedade que ocupa as encostas, com vistas a conduzi-los a região de menor risco, quando se enfrenta eventos de precipitação.

Atualmente os critérios utilizados pelo Sistema Alerta Rio são baseados em modelo gráfico determinístico, que implica no uso de limiar pluviométrico como referência para tomada de decisão de evacuação de áreas suscetíveis. Sendo assim, classificadores fundamentados em técnicas de aprendizado de máquina, podem ser viáveis como critério complementar para auxiliar na decisão de evacuação das áreas de risco. Dada a capacidade de reconhecer padrões em dados e fazer previsões em cima do que foi aprendido, estes modelos podem contribuir para o desenvolvimento de sistema com maior confiabilidade e eficiência.

Objetivos

O principal objetivo desta tese consiste em desenvolver metodologia que adota, como abordagem de análise, modelo de aprendizado de máquina para construção de classificador de eventos de precipitação para previsão de ocorrência de movimentos de massa. Em termos de vantagem, a utilização de modelos classificadores fundamentados em técnicas de aprendizado de máquina ofertam resposta de predição de classe e também probabilístico, além de permitir o uso de combinação de inúmeros atributos. Desta forma, espera-se contribuir para a tomada de decisão de acionamento de sirenes e de evacuação das áreas de risco.

Para estabelecimento de ambiente propício ao desenvolvimento de modelo classificador, tem-se os seguintes objetivos específicos:

- Interpretar as ocorrências de movimentos de massa na Cidade do Rio de Janeiro, correlacionando-os com elementos do espaço físico e climatológico;
- Realizar análises estatísticas descritivas e inferenciais para verificar existência de padrão comportamental em relação à ocorrência de movimentos de massa na área de estudo;
- Estabelecer e caracterizar fatores de precipitação com potencial de deflagrar movimentos de massa na cidade do Rio de Janeiro
- Estabelecer metodologia e diretrizes para estruturação e tratamentos dos dados de precipitação e de movimento de massa;
- Definir modelos de algoritmos de aprendizado de máquina para desenvolvimento dos classificadores de eventos de precipitação;
- Analisar as métricas de resposta dos modelos e eleger o modelo que apresenta melhor desempenho.

Descrição dos Capítulos

Na introdução é realizada uma breve contextualização, são abordados motivação, objetivo principal e objetivos secundários.

No capítulo 1, é apresentada a revisão bibliográfica, que é iniciada com as classificações de movimentos de massa. Em sequência, são apresentados alguns sistemas de alerta implantados em diferentes regiões do mundo e abordadas as características do Sistema Alerta Rio, tais como sua composição, seus critérios operacionais e demais particularidades.

No capítulo 2, são apresentados métodos de análise, com ênfase em métodos empíricos, os quais comportam modelos gráficos, modelos estatísticos e modelos classificadores fundamentados em técnica de aprendizado de máquina. Além disto, apresenta-se uma visão geral dos algoritmos utilizados para construção dos modelos classificadores e das etapas de treinamento, validação e de testes, dando-se ênfase para as métricas de avaliação de modelos de classificação.

No capítulo 3, tem-se a metodologia utilizada para desenvolvimento dos modelos. Abordam-se os aspectos que influenciaram na definição da área de estudo, são descritos critérios para seleção de amostras, formas de modulação da precipitação, etapas gerais do tratamento de dados de chuva e de movimentos de massa e apresentadas as diretrizes principais utilizadas na aplicação das técnicas de aprendizado de máquina, tal como taxa de segregação de amostras e intervalos de hiperparâmetros.

No capítulo 4, são mostrados os resultados obtidos para os 6 (seis) modelos desenvolvidos e, também, as análises individuais correspondentes.

No capítulo 5, tem-se uma análise comparativa dos resultados obtidos pelos modelos com as modulações de precipitação MP01 e MP02.

No capítulo 6, é apresentada a forma de aplicação, de uso do modelo que apresentou melhor desempenho dentre os 6 (seis) modelos construídos.

No capítulo 7, são mostradas as conclusões originadas das análises efetuadas para os modelos construídos e sugeridas linhas de estudo para pesquisas futuras.

Posteriormente aos capítulos, tem-se as referências bibliográficas utilizadas para composição da tese e seus APÊNDICES.

No APÊNDICE A estão explicitadas as tabelas com os dados de entrada utilizados na construção dos modelos de classificação.

No APÊNDICE B estão explicitadas as tabelas com os dados de chuva e movimentos de massa utilizados para realização dos estudos estatísticos preliminares.

No APÊNDICE C estão apresentados os resultados das métricas de treinamento, validação e teste, para classes desbalanceadas, dos modelos desenvolvidos.

1 RELAÇÃO CHUVA VS MOVIMENTO DE MASSA

A estabilidade de encostas é um problema típico da área da mecânica dos solos e depende da geometria da superfície da encosta, da estratigrafia, da resistência do solo que a compõe, dos efeitos da presença de água, do tipo de cobertura vegetal, dentre outros aspectos que podem ser elencados em função de características peculiares de cada encosta (Gerscovich, 2012). Estas condicionantes de estabilidade são extremamente variantes e a análise de estabilidade de taludes está diretamente relacionada à quantificação delas.

De modo geral, métodos geotécnicos de análise de estabilidade, fundamentados em parâmetros de resistência do solo, tais como ângulo de atrito (ϕ') e intercepto de coesão (c') e efeitos da condição de não saturação, são aplicados a estudos específicos e em uma região de interesse bem definida. A obtenção de parâmetros de resistência depende de delimitação de pontos geográficos de onde serão coletadas amostras para caracterização do perfil geotécnico e realização de ensaios. Com base na definição do perfil geotécnico (estratigrafia e nível d'água/linha freática) e nos parâmetros de resistência desenvolve-se análise de estabilidade (Gerscovich, 2012), seguida de discussão dos resultados e definição de condições críticas para deflagração de movimentos de massa. Este fluxo de etapas envolve elevado investimento de recursos, o qual se torna impeditivo quando se trata de escala regional.

Em grandes áreas, métodos de fundamentação empírica, tais como modelos gráficos (Item 2.1), modelos estatísticos (Item 2.2) ou modelos lastreados em técnicas de aprendizado de máquina (Item 2.3), têm se apresentado mais convenientes, principalmente em função da sua flexibilidade em agregar dados oriundos da observação do meio físico. Ao recorrer a estes modelos, que diferem da análise geotécnica clássica de estabilidade de taludes, contorna-se a necessidade de investimentos para obtenção de informações detalhadas sobre a estratigrafia e parâmetros de resistência dos materiais.

Em grandes áreas, com vistas a mitigar os efeitos catastróficos dos movimentos de massa, instituições governamentais vêm procurando alternativas para implantação de sistemas de alerta (Item 1.2) em áreas classificadas como suscetíveis à movimentos de massa, que se convertem em áreas de risco na presença de eventos de precipitação.

A correlação entre os registros de movimentos de massa e intensidades de precipitação possibilita o estabelecimento de limiares pluviométricos críticos, graficamente representados a partir de interpretação, empírica, de dados de precipitação associados ou não associados a movimentos de massa. A primeira correlação gráfica de que se tem registro, no Brasil, foi proposta por Guidicini e Iwasa (1976), para regiões em São Paulo e no Rio de Janeiro.

Em alternativa à aplicação de métodos gráficos, surgiram métodos estatísticos inferenciais para obtenção de uma relação entre precipitação e movimentos de massa, (Berti *et al.*, 2012).

Mais recentemente, o uso de técnicas de aprendizado de máquina tem se difundido em diversos campos de estudo da Geociência, inclusive na geração de mapas de susceptibilidade. Possivelmente, este fato se deve ao grande número de dados gerados a partir da universalização do Sistema de Informação Geográfica (SIG), uma vez que a disponibilidade de dados caracterizadores de uma região permite o uso de tecnologias computacionais avançadas para desenvolvimento de pesquisas.

1.1 Movimentos de Massa

Os termos escorregamento ou deslizamento são adotados quando se tem a intenção de generalizar o desprendimento/movimento de algum material de solo e/ou de rocha. Entretanto, considerando-se as classificações de Cruden e Varnes (1996), estes termos caracterizam um tipo de movimento bem definido, denominado por eles de *slide*.

Desta forma, movimento de massa é o termo apropriado para caracterizar genericamente um desprendimento, como leva a intuir a classificação de Cruden e Varnes (1996). Ainda, segundo Montoya (2013) o uso generalizado dos termos deslizamento ou escorregamento pode ter origem na tradução equivocada da palavra *landslide* para a língua portuguesa. A tradução mais adequada é movimento de massa. As palavras *landslide*, *mass movement* e *slope failure* podem ser usadas como sinônimos (Guzzetti *et al.* 2012, apud Montoya, 2013).

Gerscovich (2012) caracteriza movimento de massa por “qualquer deslocamento de um determinado volume de solo”. Em geral, a literatura trata os movimentos de massa como processos associados a problemas de instabilidade de taludes.

Talude é uma superfície inclinada de um maciço de solo ou rocha, que pode ter sido ou não construído pelo homem (Figura 1). Os taludes, denominados encostas, são em geral constituídos por solo residual e ou coluvionar, além de rocha. Solos residuais são aqueles provenientes da decomposição das rochas que se encontram no próprio local em que se formaram, já os coluvionares são transportados por ação da gravidade, vento e/ou água. Em relação à forma, os taludes podem possuir superfície plana ou curvilínea (côncava ou convexa), fazendo variar a direção do fluxo de água superficial.



Figura 1 - Região Serrana do Rio de Janeiro - 2011 (CPRM, 2013)

1.1.1 Agentes e Causas

No Brasil e no mundo, movimentos de massa não ocorrem exclusivamente em razão dos fatores do meio físico como pluviosidade, declividade, formato da encosta, orientação da vertente, características pedológicas e geológicas, que são determinantes nesse tipo de processo, mas também pela ação antrópica.

As ações antrópicas provocam interferências na rede de drenagem e no uso e ocupação do solo (eliminação da cobertura vegetal, cortes para abertura de novas estradas, construção de muros, taludes mal dimensionados, lançamento de lixo nas encostas etc.).

Os taludes naturais são suscetíveis a problemas de instabilidade devido às forças gravitacionais que contribuem para a deflagração do movimento. É comum observar encostas, que se mantiveram estáveis por muitos anos, sofrerem processos de movimentação. Nestes casos a instabilidade é consequência da própria dinâmica de evolução das encostas. Com avanço dos processos físico-químicos, o material resultante se torna menos resistente e, dependendo da influência da topografia, geram-se condições propícias para deflagrar a ruptura.

Sob o ponto de vista técnico, a correlação entre agente e causa é importante para a compreensão dos movimentos de massa. Por exemplo, o agente “água” pode influenciar na estabilidade de várias formas, seja por umedecimento do solo, que resulta em aumento das cargas atuantes, seja pela redução da sucção ou aumento da poropressão, que resulta na redução da resistência ao cisalhamento.

De acordo com Guidicini e Nieble (1984), os agentes podem ser divididos conceitualmente de duas maneiras: os predisponentes e os efetivos. Os agentes predisponentes referem-se ao conjunto de características intrínsecas onde o movimento de massa ocorre em função apenas das condições naturais, ou seja, sem a ação do homem e estes se subdividem em:

- Complexo Geológico: tipo de rocha, estrutura da rocha, estado de alteração, direção das camadas, grau de fraturamento etc.;
- Complexo Geomorfológico: declividade, forma da encosta, comprimento da encosta, orientação etc.;
- Complexo Hidrológico: clima, volume e intensidade das precipitações, dinâmica da água no solo etc.;
- Gravidade;
- Calor solar;
- Tipo de vegetação original;

Os agentes efetivos são caracterizados pelo conjunto de elementos diretamente responsáveis pelo desencadeamento do movimento de massa, neles se incluindo a ação humana. Esses podem ainda se subdividir em razão de sua maneira de atuação:

- Efetivos preparatórios: pluviosidade, erosão pela água ou pelo vento, congelamento e degelo, variação de temperatura, ação humana, desflorestamento etc.;

- Efetivos imediatos: chuva intensa, fusão do gelo e neve, erosão, terremotos, ondas, vento, ação do homem etc.;

No tocante às causas, Terzaghi (1928,1950, apud Guidicini e Nieble, 1984) as dividiu, em função das suas posições no talude, da seguinte maneira:

- **Causas internas:** são as que levam a ruptura sem a constatação de qualquer alteração geométrica do talude e que ocasionam perda de resistência interna do material (aumento da pressão hidrostática, diminuição da resistência - coesão e do ângulo de atrito interno).
- **Causas externas:** provocam um aumento das tensões de cisalhamento, sem que haja diminuição da resistência do material (aumento da inclinação do talude por processos naturais ou artificiais, decomposição do material na parte superior do talude, abalos sísmicos e vibrações).
- **Causas intermediárias:** resultam de efeitos causados por agentes externos no interior do talude (liquefação espontânea, rebaixamento rápido, erosão retrogressiva).

A instabilidade do talude é deflagrada quando as tensões cisalhantes mobilizadas, na massa do solo, atingem a resistência ao cisalhamento do material ao longo de uma superfície contínua. A condição de Fator de Segurança (FS) igual a 1 (um), em que as tensões resistentes se igualam às tensões mobilizadas (Figura 2), pode ocorrer por aumento das tensões cisalhantes mobilizadas ou redução da resistência ao cisalhamento. Desta forma, os fatores deflagradores dos movimentos de massa podem ser separados em dois grupos, aumento da sollicitação e redução da resistência, como mostra a Tabela 1.

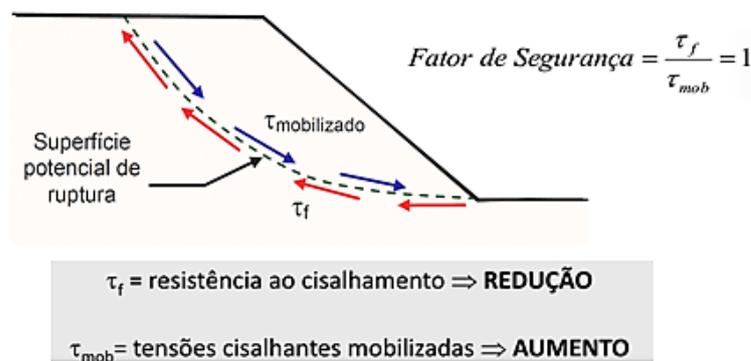


Figura 2 - Condição de ruptura por movimentos de massa (Modificado de Gerscovich, 2012)

Tabela 1 – Classificação dos fatores deflagradores dos movimentos de massa (Modificada de Varnes 1978)

| Ação | Fatores | Fenômenos Geológicos/Antrópicos |
|--|--|---|
| Aumento da solicitação | Remoção de massa (lateral ou da base) | <ul style="list-style-type: none"> ✓ Erosão ✓ Escorregamentos ✓ Cortes |
| | Sobrecarga | <ul style="list-style-type: none"> ✓ Peso da água, neve, granizo etc. ✓ Acúmulo natural de material (depósitos) ✓ Peso da vegetação ✓ Construção de estruturas, aterros etc. |
| | Solicitações dinâmicas | <ul style="list-style-type: none"> ✓ Terremotos, ondas, vulcões etc. ✓ Explosões, tráfego, sismos induzidos |
| | Pressões laterais | <ul style="list-style-type: none"> ✓ Águas em trincas ✓ Congelamento ✓ Material expansivo |
| Redução da resistência ao cisalhamento | Características inerentes ao material (geometria, estruturas etc.) | <ul style="list-style-type: none"> ✓ Características geomecânicas do material |
| | Mudanças ou fatores variáveis | <ul style="list-style-type: none"> ✓ Ação do intemperismo provocando alterações físico-químicas nos minerais originais, causando quebra das ligações e gerando novos minerais com menor resistência. ✓ Processos de deformação em decorrência de variações cíclicas de umedecimento e secagem, reduzindo a resistência. ✓ Variação das poropressões. ✓ Elevação do lençol freático por mudanças no padrão natural de fluxo (construção de reservatórios, processos de urbanização etc.) ✓ Infiltração da água em meios não saturados, causando redução das pressões de águas negativas (sucção). ✓ Geração de excesso de poropressão, como resultado de implantação de obras. ✓ Fluxo preferencial através de trincas ou juntas, acelerando os processos de infiltração. |

1.1.2 Sistemas de Classificação

Existem diversas propostas de sistemas de classificação de movimentos de massa, tais como as classificações de Varnes (1978), de Hutchinson (1988), de Guidicini e Nieble (1984), de Cruden e Varnes (1996), de Santos (2004), de Hungr et al (2014) etc..

As classificações de Varnes (1978), posteriormente modificada por Cruden e Varnes (1996) e, também por Hutchinson (1988) são as mais difundidas e utilizadas na comunidade científica (Montoya, 2013). Entretanto, em 2014, Hungr *et al* apresentaram uma atualização da classificação de Varnes (1978).

Varnes (1978) adota os tipos de movimento e de material como critérios de classificação, a partir dos quais denomina 5 (cinco) tipos de movimentos: quedas (*falls*), tombamentos (*topples*), deslizamentos (*slides*), espalhamentos (*spreads*), escoamentos ou corridas (*flows*); e define duas classes de material: rocha e solo (detritos e terra). Cruden e Varnes (1996) propuseram modificações para a classificação proposta por Varnes (1978), as quais resultaram em um novo método de classificação (Tabela 2 e Tabela 3).

Tabela 2. Classificação Principal - Movimentos de massa (Cruden e Varnes, 1996)

| Tipo de Movimento | Tipo de Material | | |
|---------------------------------|--|--------------------------------|------------------------|
| | Rocha | Solos | |
| | | Predominantemente Grosso | Predominantemente Fino |
| Quedas | Queda de blocos | Queda de detritos | Queda de solo |
| Tombamentos | De rocha | De detritos | De solo |
| Deslizamentos (Escorregamentos) | Rotacionais de rocha | Rotacionais de rocha e solo | Rotacionais de solo |
| | Translacionais de rocha | Translacionais de rocha e solo | Translacionais de solo |
| Expansões Laterais | De rocha | De detritos | De solo |
| Corridas (Escoamentos) | Rastejo de rochas (Creep) | Rastejos e corridas | |
| Complexos | Combinações de dois ou mais movimentos | | |

Tabela 3. Classificação Complementar – Velocidade dos Movimentos de massa (Cruden e Varnes, 1996)

| Classe | Descrição | Velocidade | Velocidade típica |
|--------|---------------------|--------------------|-------------------|
| 7 | Extremamente rápido | $> 5 \times 10^3$ | m/s |
| 6 | Muito rápido | 5×10^3 | m/s |
| 5 | Rápido | 5×10^1 | m/min |
| 4 | Moderado | 5×10^{-1} | m/h |
| 3 | Lento | 5×10^{-3} | m/mês |
| 2 | Muito lento | 5×10^{-5} | m/ano |
| 1 | Extremamente lento | 5×10 | mm/ano |

O método de classificação atualizado por Cruden e Varnes (1996) mantém os 6 (seis) tipos de movimentos e os 2 (dois) tipos de materiais propostos originalmente por Varnes (1978). Para eles, qualquer movimento de massa pode ser classificado e descrito por 2 (dois) nomes; o primeiro descreve o tipo de movimento e o segundo descreve o material. Além disso, eles consideram 2 (dois) aspectos mensuráveis: o conteúdo de água (seco, úmido, molhado, muito molhado) e a velocidade, que caracterizam o material e o movimento, respectivamente.

A maioria das classificações tem aplicabilidade regional e se baseia nas condições geológicas e climáticas locais. No Brasil, há algumas propostas para adequar a classificação dos movimentos de massa a ambientes tropicais (Vargas, 1985; Costa Nunes, 1969 apud Advincula, 2016). Ainda, segundo Advincula (2016) a proposta de classificação de Vargas foi revisada e ajustada, por Augusto Filho em 1992, às características dos principais grandes grupos de processos de movimentos de massa à dinâmica ambiental brasileira.

Santos (2004), com base na observação de grande número de movimentos de massa desenvolvidos na Serra do Mar, tipificou os padrões de movimento de massa quanto ao modo de desenvolvimento do movimento de massa e os comparou com suas próprias causas. O autor subdividiu as ocorrências de movimento de massa em 2 (dois) grandes grupos: naturais e induzidos. A partir dos 2 (dois) grupos, Santos (2004) estabeleceu uma nomenclatura em função da velocidade e do tipo de movimento. Na Tabela 4 são apresentadas algumas nomenclaturas para cada grupo.

Tabela 4. Padrões de Movimento de Massa (Santos, 2004)

| Tipos | | Características |
|----------|--|---|
| Naturais | Rastejo | Movimentos de grande lentidão e intermitência no horizonte superior de solos superficiais |
| | Escorregamentos translacionais rasos (ou planares) | Desmonte hidráulico de solos superficiais especialmente associado a encostas retilíneas com inclinação acima de 30° e rupturas positivas de declive |
| | Corrida de lama | Violenta torrente fluida de massa de solo e rocha ao longo dos talwegues de vales encaixados, originada da confluência do material de inúmeros escorregamentos planares ocorrido nas vertentes desse vales. |
| | Movimentação de tálus e corpos coluvionares | Movimentação de grandes massas coluvionares, quando cortadas ou sobrecarregadas por algum tipo de intervenção humana. |

| Tipos | | Características |
|-----------|--|---|
| Induzidos | Escorregamentos rotacionais profundos | Escorregamentos de grandes massas de solo, devidos especialmente a escavações de pé de talude, sobrepeso, alterações de drenagem, desmatamento etc. |
| | Escorregamentos translacionais rasos (ou planares) | Por cortes no terreno, concentração de águas superficiais, desmatamento, sobrepesos de aterros ou lixos etc. |

Adicionalmente, Hungr *et al.* (2014) propuseram uma atualização (Tabela 5) do método de classificação proposto por Varnes (1978) com o objetivo de redefinir os materiais que formam os movimentos a partir da compatibilização de terminologias geológicas e geotécnicas. Esta atualização possui 32 categorias, dentro as quais movimentos complexos não figura, e é sugerido que, caso aplicável sob o ponto de vista dos usuários, pode-se combinar categorias para criar composições.

Tabela 5. Versão atualizada da Classificação de Varnes (Modificado de Hungr et al, 2014)

| Tipo de Movimento | Rocha | Solo |
|--------------------------------|------------------------------------|--|
| Queda | Queda de rochas/gelo* | Queda de pedregulho/detrimento/silte* |
| Tombamento | Tombamento de bloco de rocha* | Tombamento de cascalho/areia/silte* |
| | Tombamento a flexão de rocha | |
| Escorregamento ou deslizamento | Escorregamento rotacional de rocha | Escorregamento rotacional de argila/silte |
| | Escorregamento planar de rocha* | Escorregamento planar de argila/silte |
| | Escorregamento em cunha de rocha* | Escorregamento de pedregulho/areia/detrimento* |
| | Escorregamento de rocha | Escorregamento composto de argila/silte |
| | Escorregamento irregular de rocha* | |
| Espalhamento Lateral | Espalhamento de Talude de Rocha | Espalhamento de areia/silte |
| | | Liquefeito* |
| Fluxo | Avalanche de rocha/gelo* | Espalhamento de argila sensível* |
| | | Fluxo seco de areia/silte/detrimento |
| | | Corrida úmida de areia/silte/detrimento* |
| | | Fluxo úmido de argila sensível* |
| | | Corrida de detrito* |
| | | Corrida de lodo* |

| Tipo de Movimento | Rocha | Solo |
|----------------------|----------------------------------|------------------------------|
| | | Inundação de detrito |
| | | Avalanche de detrito* |
| | | Fluxo de terra |
| | | Fluxo de turfa |
| Deformação de Talude | Deformação de talude de montanha | Deformação de talude de solo |
| | Deformação de talude de rocha | Rastejo de solo |
| | | Solifluxão |

*Movimentos que usualmente atingem velocidades extremamente altas – Cruden e Varnes (1996).

1.2 Sistemas de Alerta

Sistemas de alerta são ferramentas utilizadas para evacuação de áreas suscetíveis à manifestação de fenômenos naturais capazes de modificar circunstancialmente as condições físicas da região. Tais fenômenos naturais podem ser sismos, tempestades complexas, como ciclones, furacões e tufões, ou chuvas rigorosas. Seus efeitos são usualmente catastróficos, tanto em termos econômicos quanto sociais.

Abreu (2022, apud UNICAMP, 2022) sinaliza que sistemas de alerta são classificados como medidas não-estruturais, uma vez que não abarcam intervenções de infraestrutura ou ações de formatação do ambiente.

Em termos de funcionamento, estes sistemas adotam algum modelo de correlação para fins de emissão de alarmes à população. O sinal é acionado quando existe alta probabilidade de ocorrência de eventos de risco.

A tomada de decisão da emissão do alarme deve-se antecipar ao momento crítico, ou seja, o aviso sonoro deve ocorrer considerando-se que há tempo suficiente para permitir a evacuação de pessoas. Adicionalmente, este deve ser dirigido exclusivamente para a potencial área de risco, evitando assim a mobilização desnecessária de pessoas e a percepção por parte da população de que o toque da sirene é algo banal.

Tratando-se de deflagração de movimentos de massa, o risco está, comumente, relacionado à ocorrência de precipitação, embora esta não seja fator contributivo único. Nestes casos, os sistemas de alerta são baseados no volume de chuva que incide na superfície do terreno, sendo este captado por instrumentos instalados em pontos estratégicos na região de interesse.

A eficiência de um sistema de alarme pode ser obtida a partir do número de acertos e de erros de uma previsão em confronto com a quantidade de ocorrências de movimentos de massa que realmente foram deflagrados. A elaboração de uma matriz de confusão (Figura 3) permite a realização deste confronto entre realidade e previsão e, como resultado, oferta métricas de avaliação de eficiência (item 2.4.2).

Com isso, permite-se a quantificação de falso-negativo e de falso-positivo que refletem a qualidade do modelo preditivo. O falso-negativo representa eventos em que a previsão de ocorrência de movimentos de massa foi negativa, mas que, na realidade, houve deflagração de movimento. O falso-positivo ou alarme falso é caracterizado por eventos em que houve acionamento das sirenes e/ou evacuação da área sem, entretanto, ter ocorrido movimento de massa.

| | | Realidade | |
|----------|---|--------------------------|--------------------------|
| | | 0 | 1 |
| Previsão | 0 | Verdadeiro Negativo (VN) | Falso Negativo (FN) |
| | 1 | Falso Positivo (FP) | Verdadeiro Positivo (VP) |

Figura 3 – Matriz de Confusão – Classificação Binária

Em modelos preditivos, regularmente se objetiva reduzir a quantidade de falso-negativo, principalmente quando há vidas envolvidas. Por outro lado, a intolerância a falsos-negativos pode refletir no aumento de falso-positivo e, em consequência, a alta taxa de eventos falso-positivo, pode gerar desconfiança e reduzir a credibilidade no sistema de alerta.

De modo geral, tratando-se de sistemas de alerta de movimentos de massa, Guzzetti *et al.* (2020) enumeraram e analisaram 26 (vinte e seis) modelos de sistemas de alerta distribuídos em categorias nacional, regional ou global e pertencentes a diversas regiões do mundo. O intervalo temporal analisado percorre o período de 1977 a 2019. Dentre os modelos listados, os sistemas de alerta mais antigos e ainda em operação pertencem, em primeiro lugar, à Hong Kong e, em segundo lugar, à cidade do Rio de Janeiro.

Os sistemas de alerta de Taiwan e da Itália também são citados em termos de temporalidade. Embora o sistema de Taiwan seja 8 (oito) anos mais antigo que o italiano, o sistema da Itália abrange uma área territorial aproximadamente 8 (oito) vezes maior. Na Itália, o sistema conta com 1950 pluviômetros, enquanto o de Taiwan possui em torno de 300 pluviômetros. Serão detalhados a seguir, os sistemas de alerta nacionais da Itália e do Japão e os sistemas de alerta regional de Hong Kong e da Prefeitura do Rio de Janeiro (Alerta-Rio).

1.2.1 Itália

O Sistema Nacional de Alerta – SANF está operando desde 2008 e ao longo de seus primeiros 10 (dez) anos de funcionamento passou por inúmeras alterações. Na versão atual o SANF adota, como atributos, chuva acumulada (mm) e duração (h) para estabelecimento de limiar pluviométrico para previsão da deflagração de movimentos de massa (Guzzetti *et al.*, 2020).

Para desenvolvimento do limiar pluviométrico em vigor, foram adotados uma rede (Figura 4), que é composta por 2228 pluviômetros, e um inventário com 2309 movimentos de massa deflagrados no intervalo temporal de 19 (dezenove) anos, entre 1996 e 2014, em que a maioria dos movimentos de massa se concentra no período de 2008 a 2011 (Peruccacci *et al.*, 2017).

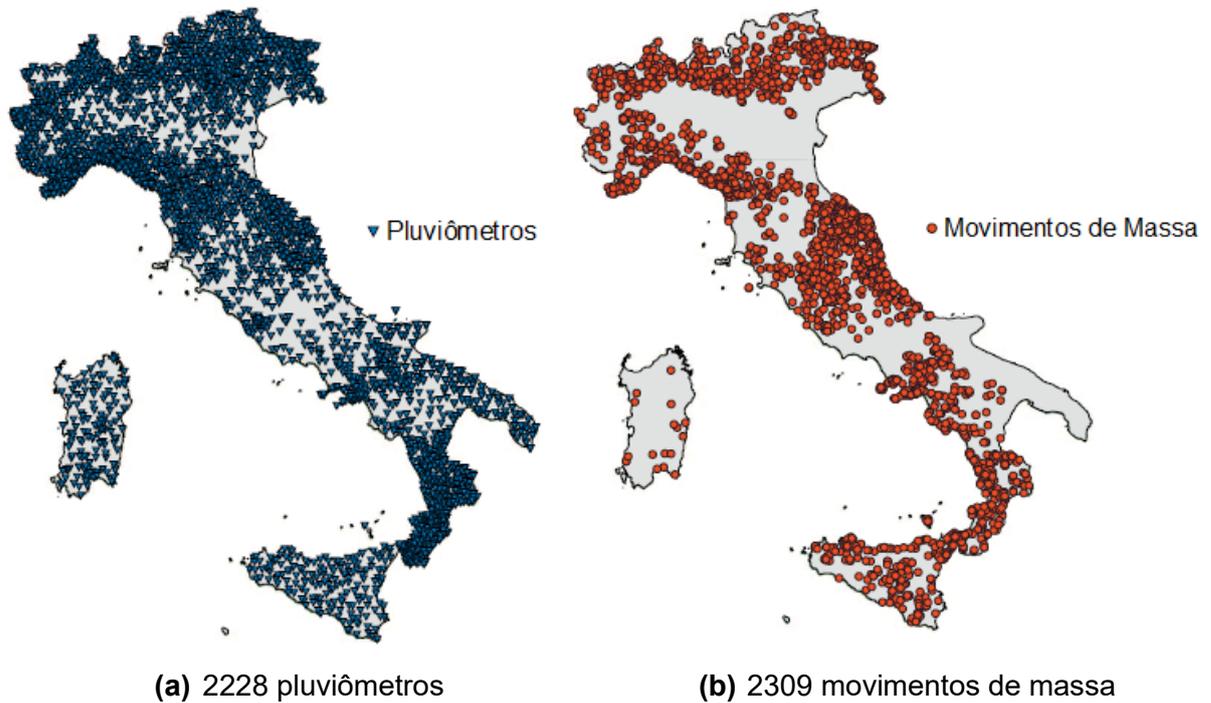


Figura 4 – Distribuição geográfica (Peruccacci *et al.*, 2017)

A partir da relação entre precipitação acumulada, duração da precipitação e a ocorrência de movimentos de massa, Peruccacci *et al.* (2017) estabeleceram o limiar pluviométrico conforme apresentado na Figura 5, dado pela Equação 1:

$$E = 7,7 \pm 0,3D^{(0,39 \pm 0,009)} \quad (1)$$

Onde E é a acumulada de chuva e D é a duração da chuva.

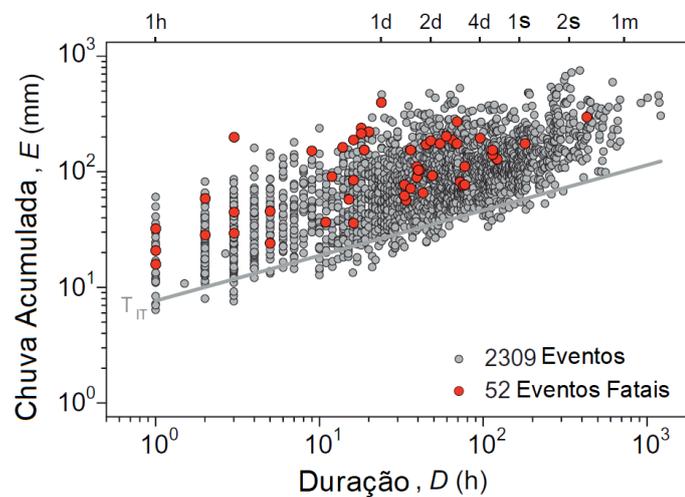


Figura 5 – Limiar Pluviométrico em escala logarítmica – Itália (Peruccacci *et al.*, 2017)

Segundo Rossi *et al.*(2012), duas vezes por dia, o sistema compara a precipitação prevista com os limiares de acumulada-duração (ED) pré-definidos e atribui uma probabilidade de ocorrência de movimentos de massa, utilizando para tal um algoritmo desenvolvido para este fim específico. A probabilidade de ocorrência de movimentos de massa é usada para preparar mapas de suscetibilidade em escala, delimitando áreas com maior probabilidade de deflagração de movimentos de massa. A Figura 6 mostra o fluxograma do sistema de alerta italiano.

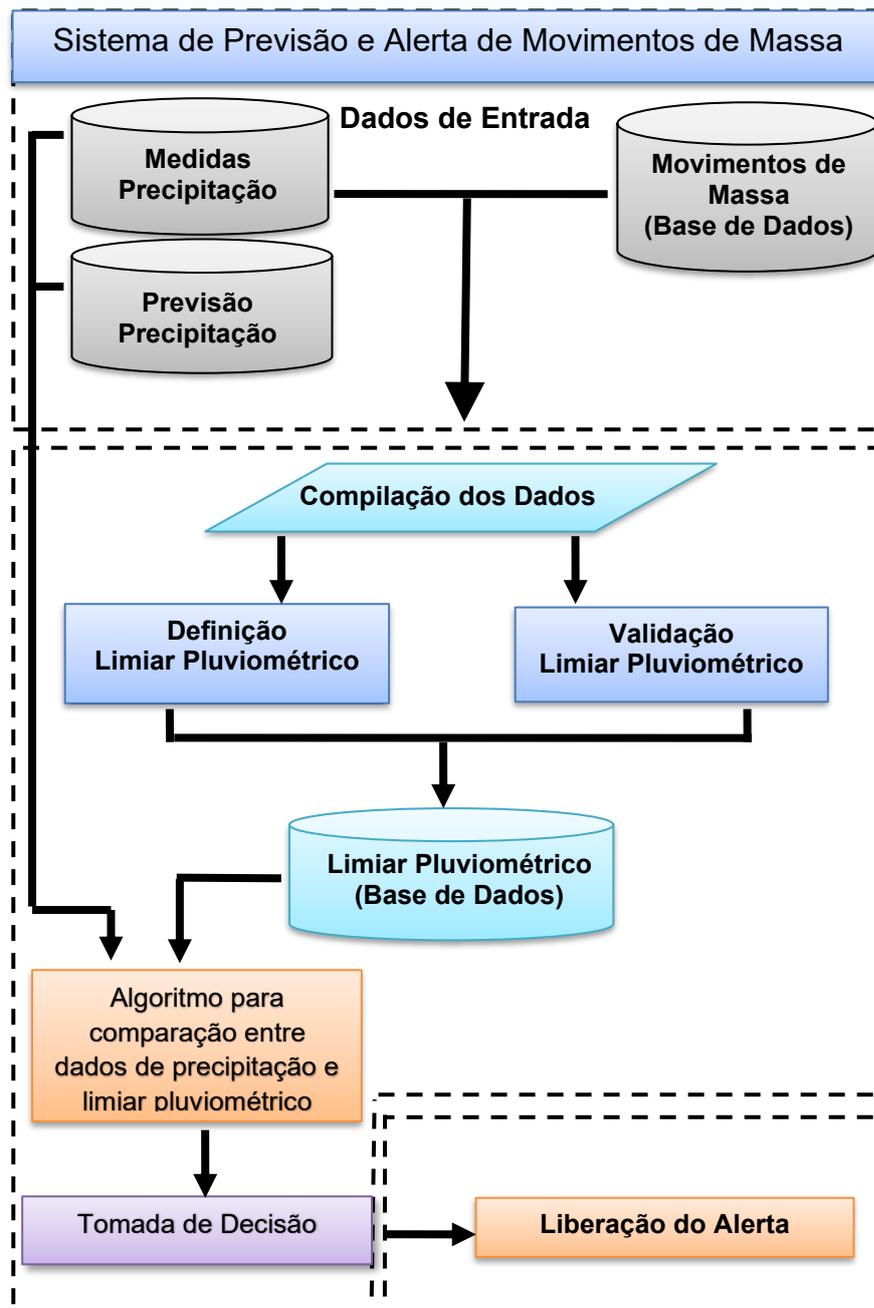


Figura 6 – Fluxograma do sistema de alerta italiano (a) precipitação e entrada para armazenamento de dados, (b) processamento e análise de dados, e (c) produção e entrega das previsões. (Modificado de Rossi *et al.*, 2012)

1.2.2 Japão

Face à experiência do Japão, foi estabelecido com o Brasil um acordo de cooperação bilateral para desenvolvimento do Projeto GIDES-JICA (CEMADEM, 2022), que perdurou de 2013 a 2017. O Projeto GIDES é composto por 4 (quatro eixos): Mapeamento de Perigo e Risco a Movimentos Gravitacionais de Massa; Monitoramento e Alerta; Obras de Prevenção e Reabilitação; e Planejamento da Expansão Urbana. Os Volumes 1 a 6, produtos resultantes desta parceria, estão disponibilizados pelo antigo Ministério de Desenvolvimento Regional (MDR, 2019).

- Volume 1 - Manual Técnico para Mapeamento de Perigo e Risco a Movimentos Gravitacionais de Massa;
- Volume 2 - Manual Técnico para Elaboração, Transmissão e Uso de Alertas de Risco de Movimento de Massa;
- Volume 3 - Manual Técnico para Planos de Contingência para Desastres de Movimento de Massa;
- Volume 4 - Manual Técnico para Intervenções Estruturais para Fluxo de Detritos;
- Volume 5 - Manual Técnico para Plano de Intervenção de Ruptura de Encosta;
- Volume 6 - Manual Técnico para Redução de Riscos de Desastres Aplicado ao Planejamento Urbano.

Desde 1984, a emissão de informações de alerta precoce no Japão é fundamentada em duas hipóteses. A primeira hipótese admite que a ocorrência de movimento de massa pode ser prevista a partir da combinação de 2 (dois) índices de precipitação, um de curto prazo e outro de longo prazo, uma vez que movimentos de massa são respostas do maciço de solo a variações causadas, tanto por águas superficiais quanto por águas subterrâneas. A segunda hipótese é que se pode identificar limiares pluviométricos em gráficos: no eixo das abscissas os índices de precipitação a longo prazo, caracterizado por índices de umidade do solo, e no das ordenadas o índice de precipitação de curto prazo, representado pela chuva acumulada de 60 minutos. Os volumes de chuva são determinados a partir de pluviômetros e o índice de umidade do solo é originado de um modelo conceitual hidrológico para cálculo de vazão (Osanai *et al.*, 2010).

A partir destes dois índices (curto e longo prazo) e com base no inventário histórico, obteve-se o limiar pluviométrico que baliza a emissão de alerta. Na Figura 7 (a) tem-se um modelo gráfico de limiar pluviométrico e na Figura 7 (b) apresenta-se um exemplo prático de aplicação do sistema de alerta.

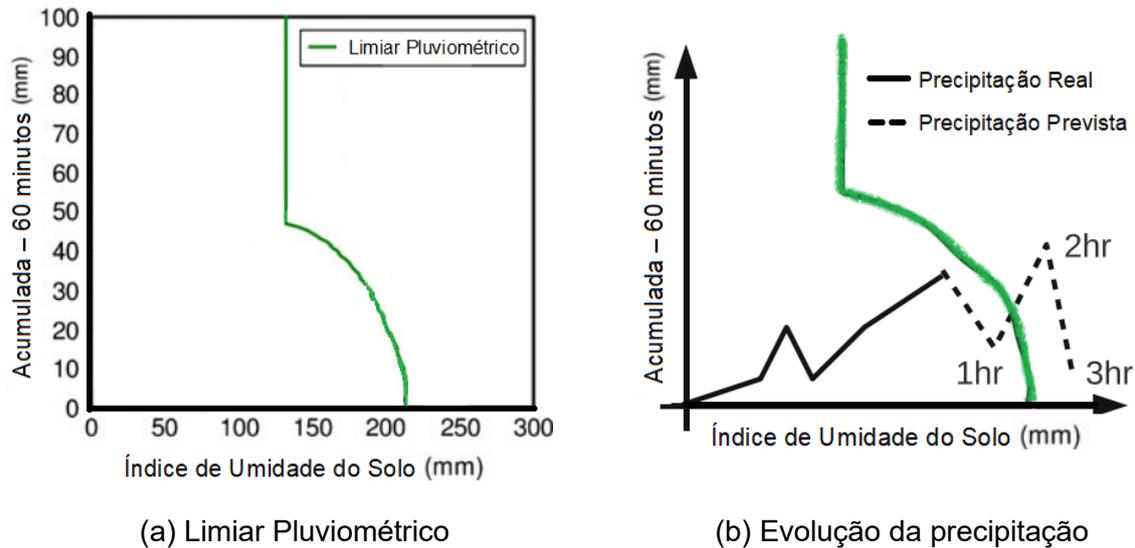


Figura 7 – Limiar Pluviométrico – Sistema Alerta Japão.
(Modificado de Osanai *et al.*, 2010)

Segundo o Manual de Alerta de Desastres de Movimento de Massa (DESC ,2005), a Agência de Meteorologia do Japão - AMJ, o Ministério dos Transportes e Infraestrutura e as províncias colaboram na publicidade e divulgação das metas e das informações de alerta de desastres de movimentos de massa. Com isso, busca-se criar condições para que, tanto as administrações locais, quanto a população estejam preparadas para se adequar a uma situação emergencial.

Na Figura 8, Osanai *et al.* (2010) apresenta o fluxo de comunicação para realização de evacuação, quando identificado evento de precipitação com potencial para deflagração de movimentos de massa.

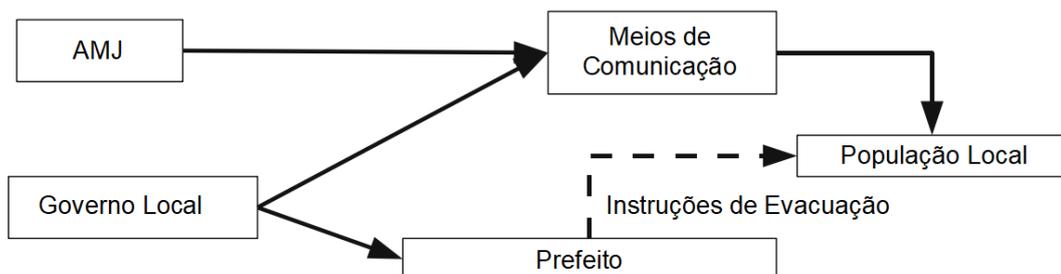


Figura 8 – Transmissão de informações de alerta. AMJ - Agência de Meteorologia do Japão
(Modificado de Osanai *et al.*, 2010)

Em termos descritivos, a organização do sistema de alerta segue os procedimentos:

- I. A Agência de Meteorologia do Japão -AMJ repassa a advertência e o alerta de chuva forte com base no Artigo 13 da Lei de Serviços Meteorológicos (Previsão e Alarme; aplicação do Artigo 15). Ao mesmo tempo, em conjunto com dados meteorológicos baseados no Artigo 11 da mesma lei (Anúncio de Resultados de Previsões), ela transmite às entidades relacionadas as informações de alerta de desastres de movimentos de massa. Após o alarme, as informações são elaboradas e anunciadas definindo-se um nível de periculosidade de ocorrência de movimentos de massa. Tal nível é estabelecido em função da previsão de chuvas, emitida pela Agência de Meteorologia do Japão;
- II. Em relação às informações, cabe às províncias a definição dos objetivos e dos demais itens de seu programa regional de prevenção de desastres. Este programa é elaborado com base no Artigo 40 da Lei Básica de Medidas contra Desastres do Japão. Quando um alarme de chuva forte é emitido, as províncias transmitem essas informações aos administradores locais. As medidas mitigadoras estão contidas no documento "Desastres de movimentos de massa previstos e medidas sugeridas", elaborado com base no Artigo 55 da Lei Básica de Medidas contra Desastres.

Os meios de comunicação possuem papel fundamental na divulgação dos alertas, é através dele que a população é informada sobre o nível de alerta para cada região ou província do Japão. Em 2019, a Agência de Meteorologia do Japão - AMJ estabeleceu novo critério de alerta (Tabela 6) com objetivo de proporcionar maior clareza à população sobre as ações que devem ser tomadas em relação à cada nível de alerta (Nippon, 2019).

Tabela 6. Níveis de Alerta - Japão (Modificado de Nippon, 2019)

| Nível de Alerta | Informação de Evacuação | Informação Meteorológica | Ação a ser realizada |
|-----------------|---------------------------|---|--|
| 1 | | Sinalização antecipada | Estar preparado/atento |
| 2 | | Sinalização de precipitação/alagamento intensos | Estabelecer/verificar rotas de evacuação |
| 3 | Preparação para evacuação | Alerta de precipitação/alagamento intensos | Realizar a evacuação de idosos ou pessoas com necessidades especiais |

| Nível de Alerta | Informação de Evacuação | Informação Meteorológica | Ação a ser realizada |
|-----------------|-------------------------|--|--|
| 4 | Ordem de evacuação | Alerta de movimento de massa | Realizar evacuação completa |
| 5 | Desastre | Alerta Emergencial de precipitação intensa | Estabelecer e tomar medidas de otimização para salvar vidas. |

1.2.3 Hong Kong

Guzzetti *et al.* (2020) sinalizam que o sistema de alerta de Hong Kong é o mais antigo dos 26 sistemas de alerta analisados e compilados em seu trabalho. Kong *et al.* (2020) afirmam que o sistema de alerta de Hong Kong foi ativado em 1977 e que, desde 2004 até os dias de hoje, está na 4ª geração.

O sistema de alerta de Hong Kong é baseado nos registros de chuvas dos postos pluviográficos. Esses equipamentos registram a intensidade das chuvas, continuamente, através de um mecanismo capaz de traçar a curva representativa da evolução da chuva com o tempo.

Atualmente, o sistema de alerta utiliza medições de precipitação obtidas por uma rede densa de 122 pluviômetros, que fornecem informação atualizada a cada 5 (cinco) minutos e previsões de precipitação obtidas de radar meteorológico. Essas informações são confrontadas com relações empíricas, que correlacionam a precipitação acumulada de 24 horas (Figura 9) à densidade de movimentos de massa de terra, para taludes de cortes em solo e em rocha, para aterros e para muros de contenção de Hong Kong (Guzzetti *et al.* 2020).

Para previsão da quantidade de movimentos de massa, para cada um dos quatro tipos de intervenção em encostas, utiliza-se a quantidade de taludes existentes na malha de compartimentação do território de Hong Kong, a qual possui 1600 células de grade de 1,2 km x 1,5 km, e a precipitação acumulada de 24h (Figura 9). A Equação 2 apresenta a forma de obtenção da estimativa de movimentos de massa esperados (E):

$$E = \zeta N_s \quad (2)$$

Onde ζ é a frequência obtida pelas curvas (Figura 9) e N_s é a quantidade de taludes existentes em cada célula da malha de cobertura.

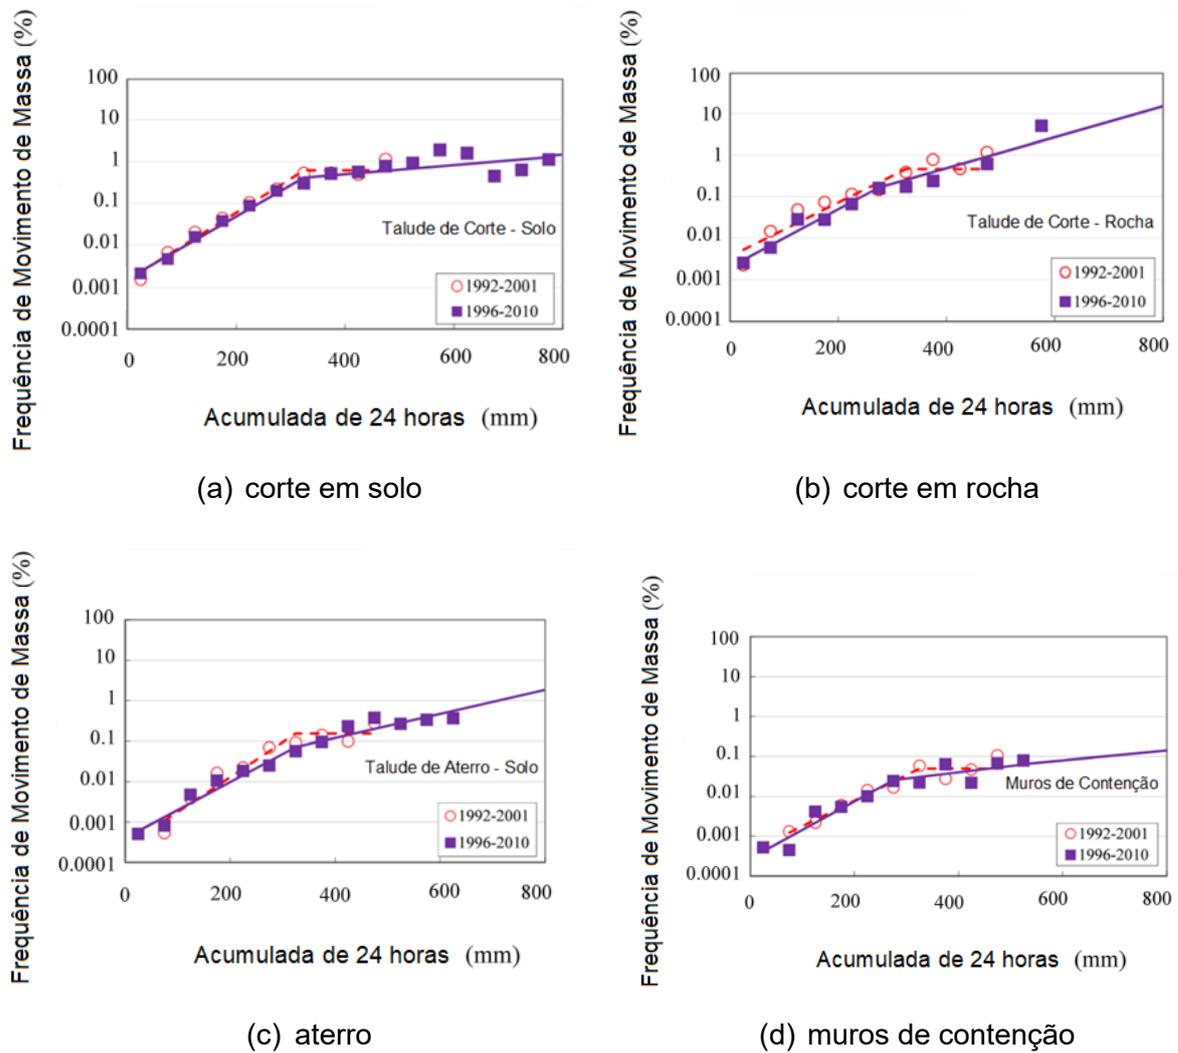


Figura 9 – Limiar pluviométrico– Hong Kong.
(Modificado de Kong *et al.*, 2020)

O sistema de alerta utiliza três níveis de aconselhamento, conforme Tabela 7. Durante a fase de “consulta” são adotadas previsões de precipitação de 1 a 3 horas com base em dados de radar. O nível de “alerta” público é atingido quando, por meio da Equação 2, estima-se $E \geq 15$. Consequentemente, avisos de movimentos de massa são divulgados para o público utilizando-se diversos meios de comunicação, incluindo um site oficial, TV e rádio canais, aplicativos de celular e redes sociais (Kong *et al.* 2020).

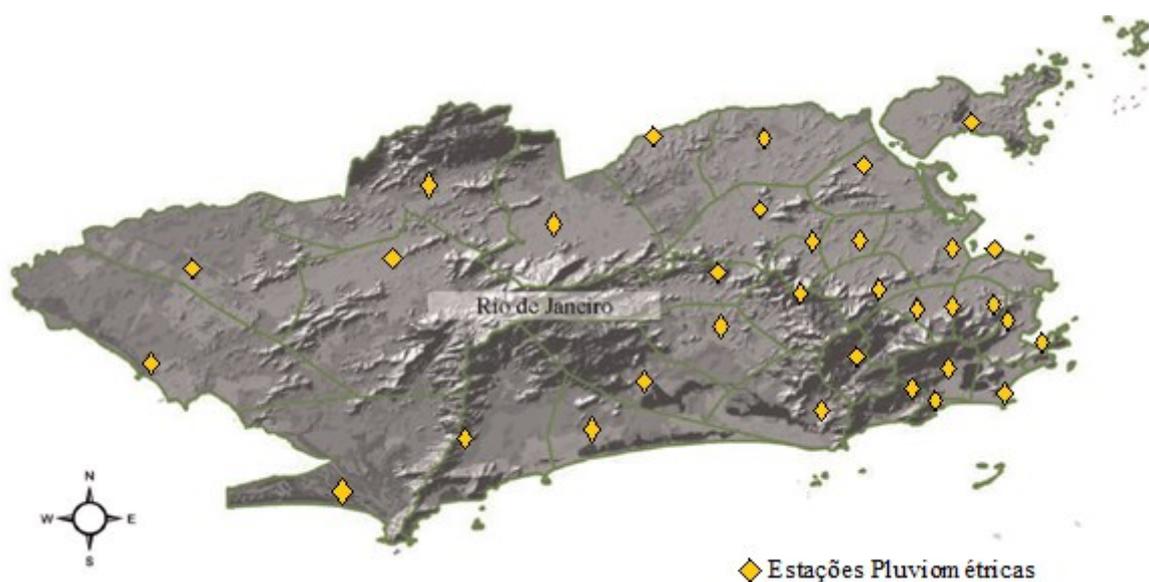
Tabela 7. Níveis de Alerta – Hong Kong (Modificado de Kong *et al.*, 2020)

| Nível de Alerta | Denominação | Caracterização |
|-----------------|-----------------------------------|--|
| 1 | Consulta (Comunicação Interna) | A acumulada de 24h excedeu 100mm em 10 ou mais pluviômetros |
| 2 | Atenção (Comunicação Interna) | A acumulada para atingir o nível de alerta 3 é menor do que 100 mm |
| 3 | Alerta (Comunicação Externa) | Número de movimentos de massa previsto é 15 ou mais |

1.2.4 Município do Rio de Janeiro

O Sistema Alerta-Rio foi criado em 1996, em atenção aos eventos de movimentos de massa registrados na cidade do Rio de Janeiro nos anos anteriores, e desde 1997 é disponibilizado, em site próprio, dados de precipitação registrados, além de relatórios anuais, elaborados desde 2001.

O sistema se baseia no monitoramento automático dos índices pluviométricos por meio de 33 estações (Figura 10) distribuídas em 4 (quatro) zonas de alerta (Figura 11). A Fundação Geo-Rio, da Prefeitura do Município do Rio de Janeiro, além de monitorar os dados pluviométricos, produz boletins de ocorrências dos todos os movimentos de massa registrados na cidade.

Figura 10 – Pluviômetros - Sistema Alerta Rio (Calvello *et al.*, 2015)

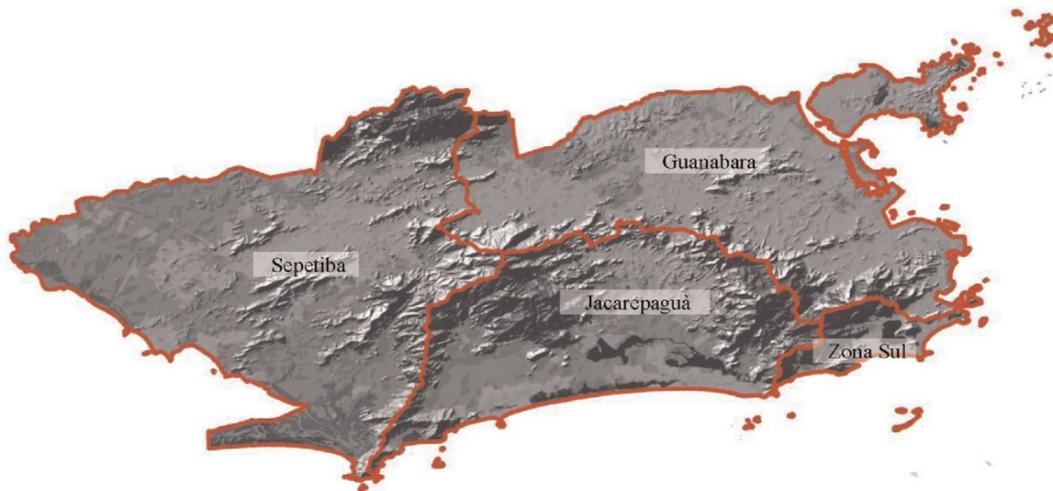


Figura 11 – Zonas de Alerta: Sistema Alerta Rio (Calvello *et al.*, 2015)

Os boletins de ocorrências contêm a localização, descrição do evento e provável data da deflagração do movimento de massa. Adicionalmente, no processo de vistoria, a ocorrência é classificada por tipologia, conforme a nomenclatura descrita na Tabela 8, o que inclui a natureza do talude (corte ou aterro), tipo de material (solo, rocha, lixo), tipo de movimento (escorregamento, queda, corrida, processos erosivos), etc.. Dependendo da tipologia, uma mesma ocorrência pode ser classificada como “Simples” ou “Composta”. Em casos de classificação “Composta”, o responsável pela visita e elaboração do boletim de ocorrência indica a tipologia predominante.

Tabela 8 – Tipologias para a classificação das ocorrências (GEO-RIO, 2010)

| Tipologia das ocorrências | | Classificação |
|--|------------------------------|---------------|
| Não se trata de ocorrências pertencentes à Geo-Rio | | 0 |
| Talude de corte | Escorregamento de solo | 1 |
| | Escorregamento de solo/rocha | 2 |
| | Escorregamento de rocha | 3 |
| Ruptura de aterro | | 4 |
| Encosta natural | Escorregamento de solo | 5 |
| | Escorregamento de solo/rocha | 6 |
| | Escorregamento de rocha | 7 |
| Queda/Rolamento de blocos ou lascas rochosos | | 8 |
| Escorregamento de tálus | | 9 |
| Ruptura de estrutura de contenção | | 10 |
| Escorregamento de lixo/entulho | | 11 |
| Corrida | | 12 |
| Processos erosivos/ assoreamento | | 13 |

O monitoramento dos eventos de precipitação que atingem as zonas de alerta da Guanabara, da Zona Sul, de Jacarepaguá ou da Sepetiba é feito em tempo real por meio dos pluviógrafos e de radares meteorológicos. Os registros são enviados para a “estação central do sistema”, em intervalos regulares de 15 minutos, possibilitando análises de intensidades de até mm/15 minutos.

A partir da combinação dos registros de pluviometria e da identificação das ocorrências, foram desenvolvidas correlações empíricas com objetivo de definir probabilidades de ocorrência de movimentos de massa. Para tal, foram estabelecidas diferentes faixas de intensidade de chuva considerando-se valores acumulados em 1h, 24h e 96h, como mostra a Tabela 9.

A definição do nível de atenção e o acionamento das sirenes ocorrem de modo interativo, a partir da comparação dos registros coletados de cada estação pluviométrica com o limiar pluviométrico geral (Tabela 9) e, também com a previsão meteorológica.

A partir deste sistema, denominado de Alerta-Rio, sirenes para evacuação das áreas de risco da Cidade do Rio de Janeiro são acionadas quando a intensidade e a duração da chuva atingem determinado limiar crítico em pelo menos três estações de uma mesma zona de alerta (Sepetiba, Jacarepaguá, Zona Sul e Guanabara - Figura 11).

Tabela 9 - Critérios operacionais do Sistema Alerta-Rio
(Alerta Rio, 2015 apud Chaves, 2016)

| Intensidade/acumuladas pluviométricas | Probabilidade de ocorrência de movimentos de massa | | |
|---------------------------------------|--|----------------------------------|---------------------------|
| | MÉDIA | ALTA | MUITO ALTA |
| mm/h | 10 a 30 mm | 30 a 50 mm | > 50 mm |
| mm/24h | 50 a 100 mm | 100 a 175 mm | > 175 mm |
| mm/96h | 100 a 175 mm e 10 a 30 mm/24h | 175 a 250 mm e 30 a 50 mm/24h | > 250mm e > 100 mm/24h |

1.2.4.1. Desempenho

O sistema Alerta-Rio foi alvo de estudo de Calvello *et al.* (2015) em termos de eficiência do critério pluviométrico (Tabela 9). Considerando-se o banco de dados relativo ao período de 2010 a 2013, os autores realizaram levantamento dos alertas falso-positivo e falso-negativo, da duração do estado de alerta e da verificação das correspondências das zonas de alerta com o critério geral de limiar.

Alertas falsos-positivos (alarme falso) são caracterizados por situações em que houve o acionamento do sistema de alerta, entretanto não foram registrados movimentos de massa, enquanto alertas falso-negativo representam eventos em que previsão da ocorrência de movimentos de massa foi negativa, mas que, na realidade, houve a deflagração de movimento.

Ainda, para desenvolvimento da análise de eficiência, Calvello *et al.* (2015) consideraram as seguintes variáveis: i) acumulada e duração dos eventos de precipitação; ii) Localização, tipologia e data de ocorrência dos movimentos de massa; iii) nível e duração dos alertas. Os resultados identificaram como pontos críticos do Sistema Alerta Rio: i) emissão de alertas falso-positivo; ii) duração dos alertas; iii) heterogeneidade das zonas de alerta.

Para cada zona de alerta: Guanabara, Zona Sul, Sepetiba e Jacarepaguá (Figura 11), os autores mostraram que, num período de 4 anos (2010-2013), as taxas de falsos-positivos foram de 0,43, 0,88, 1,0 e 0,71, respectivamente. Em outras palavras, grande parte dos acionamentos não se justificaram. Em Sepetiba, por exemplo, não houve movimento de massa. Sob essa perspectiva, evidenciou-se que o sistema poderia cair em descrédito pela população e que haveria necessidade de se refinar o critério de limiar crítico ora adotado (Tabela 9).

No que tange à relação que a população estabelece com situações de risco, Vasconcellos (2015) identificou fatores que afetam a reação da população, tais como: a influência de experiências passadas em relação ao evento; a influência da frequência de ocorrência do evento; a influência da familiaridade com a situação enfrentada; e a influência da expectativa de vida.

O trabalho foi desenvolvido junto à comunidade da Formiga, no bairro da Tijuca, na cidade do Rio de Janeiro. Desta forma, foi possível para Vasconcellos (2015) identificar que populações de comunidades tendem a possuir percepção de risco deficiente, provavelmente devido à relativização feita frente a outras ameaças vividas em sua realidade. Ele relata que, para incentivar o engajamento da população em atividades de prevenção e de gestão de riscos, faz-se necessário ações socioeducativas, que mostrem aos moradores a importância da percepção de risco, e a conscientização da relação do homem com o meio ambiente. Dado o contexto evidenciado por Vasconcellos (2015), é intuitivo concluir que a percepção de risco da população está diretamente relacionada com a credibilidade do sistema e esta, por sua vez, com uma baixa taxa de eventos falso-positivo.

De qualquer forma, cabe ressaltar que os limiares pluviométricos do Sistema Alerta Rio respondem de modo a reduzir ao máximo os alertas falsos-negativos, ou seja, aqueles em que não se aciona a sirene, mas ocorrem movimentos de massa. Por apresentar característica conservadora, essa abordagem apresenta forte tendência de produzir falsos-positivos.

Em continuidade à análise de desempenho do Sistema Alerta Rio, no que concerne à análise das chuvas mínimas e máximas registradas por cada pluviômetro (Figura 10), dentro de cada zona de alerta (Figura 11), Calvello *et al.* (2015) observaram uma grande variabilidade, mesmo dentro de uma única zona. Das 4 (quatro) zonas de alerta existentes, a zona da Guanabara foi apontada como a mais heterogênea.

Como propostas de aperfeiçoamento do sistema, Calvello *et al.* (2015) apontaram a necessidade de melhorar o critério de definição do limiar pluviométrico, no sentido de se reduzir o número de alertas falsos-positivos. Considerando-se que a redução de eficiência do sistema se acentua em decorrência da adoção de um único limiar para as 4 (quatro) zonas distintas, foi também sugerida a realização de estudos de modo a se definir limiares pluviométricos individualizados em cada zona da cidade.

Adicionalmente, Calvello *et al.* (2015) recomendaram uma revisão na definição das regiões estabelecidas como zonas de alerta. Com a análise dos registros pluviométricos, talvez fosse possível detectar comportamentos similares por grupo de pluviômetros ou por pluviômetros adjacentes, definindo-se assim zonas homogêneas de chuva, que tenderiam a ser de tamanho menor do que as zonas atuais de alerta.

O sistema de Alerta da cidade do Rio de Janeiro foi, também, alvo de análise por Guzzetti *et al.* (2020) conjuntamente com demais 19 (dezenove) sistemas de alerta distribuídos em categoria regional e pertencentes a países como Bangladesh, Canadá, Colômbia, Estados Unidos, Hong Kong, Indonésia, Itália e Taiwan. Em sua análise comparativa, Guzzetti *et al.* (2020) adotaram indicadores como: Extensão Territorial; População; Ocupação Demográfica; Clima; Geologia; Suscetibilidade a sismos; Índice de precipitação; Sistema de captação de precipitação; Estágio de evolução do sistema; Período de funcionamento e Níveis de alerta.

Em relação ao sistema de alerta do Rio de Janeiro, Guzzetti *et al.* (2020) ratificam a análise de Calvello *et al.* (2015) de que o sistema de alerta atual produz bons resultados, embora apresente número significativo de falsos-positivos. Como conclusão, sua interpretação é de que o limiar pluviométrico é conservador.

2 MÉTODOS DE ANÁLISE

A pesquisa científica é um dos pilares do conhecimento (Muccioli *et al.*, 2007) e a realização de pesquisas requer a existência de dados e de ferramentas de análise. Adicionalmente, pesquisas são desenvolvidas a partir da aplicação de métodos que podem ser analíticos ou empíricos.

Em Geotecnia, métodos analíticos abarcam, de modo sistemático, as teorias da mecânica dos solos, ou seja, aplicam os princípios teóricos para desenvolvimento da análise, definindo os parâmetros geotécnicos, aplicando as equações que descrevem os mecanismos e adotando ferramentas computacionais e/ou matemáticas para reprodução dos processos envolvidos na análise. Sob esta abordagem, o movimento de massa é analisado, usualmente, por meio de métodos de equilíbrio limite ou através da análise de tensões *vs* deformações (método dos elementos finitos). Em ambas as alternativas, obtém-se o fator de segurança à ruptura, o qual é uma métrica fundamentada na relação entre a resistência do solo e as tensões cisalhantes solicitantes, tal como apresentado em Gerscovich (2012).

Métodos analíticos são utilizados principalmente em análises “pontuais”, já que requerem a identificação de uma série de parâmetros e, conseqüentemente, a realização de investigações de campo e de laboratório. Este enfoque não se adapta ao desenvolvimento de sistemas de Alerta, uma vez que tais sistemas abrangem grandes áreas, as quais envolvem encostas com diferentes condições de ocupação, geomorfologias, estratigrafias etc.

Métodos empíricos também possuem fundamentação teórica. É a partir dela que são estabelecidas as relações de causalidade entre os fenômenos estudados e os atributos/fatores considerados na análise.

As correlações chuva *vs* movimento de massa são pautadas na relação que existe entre a umidade do solo e a resistência ao cisalhamento. Em termos geotécnicos, o aumento da poropressão e/ou redução da sucção no solo, reduz as tensões efetivas e estabelecem um novo estado de tensões (Figura 2), no qual a resistência ao cisalhamento tende a ser inferior ao estado de tensão anterior (Terzaghi, 1928,1950, apud Guidicini e Nieble, 1984). A análise de estabilidade desenvolvida empiricamente é respaldada na relação de causalidade entre a ocorrência de precipitação e a deflagração do movimento de massa.

Além da precipitação, que é um elemento climático, é possível adotar fatores físicos, tais como: inclinação do talude, tipo de solo, caracterização da cobertura vegetal etc. (Guidicini e Nieble, 1984). A definição dos tipos de atributos/fatores que comporão a análise depende do entendimento sobre a pertinência e viabilidade de incorporá-los.

Fato é que ambos os métodos, analítico e empírico, incorporam fundamentação teórica, a qual pode vir caracterizada por uma relação de causalidade, comumente adotada para a eleição de atributos/fatores utilizados em métodos empíricos, ou pode vir caracterizada a partir da aplicação de princípios e equações que conduzirão aos elementos/metodologias presentes em estudos analíticos.

Independentemente do tipo de método adotado, analítico ou empírico, faz-se necessária a definição da forma de desenvolvimento da análise, a qual está relacionada às ferramentas utilizadas para realização dos estudos.

Relativamente ao tema objeto desta pesquisa, enumeram-se as seguintes formas:

- **Abordagens Gráficas:** resultam em modelos baseados em limiares pluviométricos gráficos, que, comumente são construídos a partir de dados de origem empírica, principalmente pelo fato de se voltarem para análises cujas áreas de estudo abrangem escalas regionais;
- **Abordagens Estatísticas:** resultam em modelos estatísticos/probabilísticos, pois se desenvolvem a partir da estatística descritiva e podem evoluir com a aplicação princípios probabilísticos, como, por exemplo, funções de distribuição de probabilidade. Este tipo de abordagem inclui tanto dados originados empiricamente quanto dados originados analiticamente;
- **Abordagens Numéricas:** resultam em modelos numéricos, neste trabalho adotaremos modelos fundamentados em técnicas de aprendizado de máquina, que envolvem a extração de conhecimento diretamente de dados disponíveis, os quais podem possuir origem empírica ou analítica. Estes modelos utilizam algoritmos fundamentados em teorias probabilísticas, estatística e/ou otimização para realizar inferências, previsões e dar suporte à tomada de decisão, entre outras aplicações.

Apresenta-se a seguir uma descrição mais detalhada das abordagens de análise utilizadas em estudos relacionados ao tema deste trabalho e que, também, adotam método empírico, uma vez que este corresponde à natureza de desenvolvimento desta pesquisa.

2.1 Modelos Gráficos - Limiares Pluviométricos

A ocorrência de movimentos de massa durante ou após períodos de precipitação explicitou a necessidade de realização de análises que considerassem escala regional e induziu o desenvolvimento de correlações. Partindo-se do entendimento de que a maior parte das encostas não apresenta nível d'água, as rupturas são atribuídas à parcela da precipitação que infiltra no solo.

Neste contexto, os efeitos da infiltração da água de chuva têm sido observados e analisados há muito tempo. Lumb (1975), Rahardjo e Fredlund (1993), Ng and Shi (1998), Fourie *et al.* (1999) constataram que rupturas de talude deveriam ser atribuídas ao avanço da frente de saturação, que causa redução da sucção matricial e, conseqüentemente, da resistência ao cisalhamento na superfície potencial de ruptura.

Da mesma forma, o mapeamento das características das precipitações associadas a movimentos de massa tem sido objeto de estudo ao longo dos anos. Em 1975, Peter Lumb propôs modelo empírico de correlação a partir de estudo de dados de chuva e movimentos de massa em Hong Kong. No Brasil, Guidicini e Iwasa analisaram, em 1976, dados de precipitação e movimentos de massa de 9 (nove) regiões (8 regiões no Estado de São Paulo e 1 região no Estado do Rio de Janeiro).

Desde então tem crescido o número de propostas de correlações (Brand *et al.* (1984), Tatizana *et al.* (1987), Premchitt *et al.* (1994), Pun *et al.* (2003), D'Orsi (2011)), Hassan *et al.* (2018) e Dikshit *et al.* (2020). Estas correlações se caracterizam pela definição de uma curva que, em função da acumulada de chuva (mm) ou em função da intensidade (mm/h), estabelece um limiar pluviométrico.

A Tabela 10 apresenta um compilado de correlações gráficas propostas na literatura, além daquelas apresentadas no item 1.2, onde foram detalhados alguns sistemas de alerta que tomam partido de métodos gráficos e de limiares pluviométricos.

Tabela 10. Resumo de propostas de Limiares Pluviométricos (Modificado de Chaves. 2016)

| Referência | Local | Período | Critério para definição de evento pluviométrico | Análises / Correlação |
|--------------------------------|---|---------------------------|--|---|
| Lumb (1975) | Hong Kong | 1950 a 1973 (23 anos) | Não encontrado | Correlação: mm/24h x mm/15dias Evento severo :mm/24h ≥ 100 e mm/15dias ≥ 200 |
| Guidicini e Iwasa (1976) | São Paulo (8 áreas) e Rio de Janeiro (1 área) | 1928 a 1976 (48 anos) | Acumuladas de chuva a partir de 130mm ± 7%. | Definição de zonas A, B, C e D em função da razão entre a magnitude da precipitação acumulada ocorrida até o dia anterior ao evento e a magnitude média de chuva anual (Cc). |
| Brand <i>et al.</i> (1984) | Hong Kong | - | Não encontrado | Fortemente relacionada à precipitação de 24h (mm/24h), Pouca influência da acumulada de 15 dias Evento severo mm/h ≥ 70 mm. Evento sem movimentos de massa: mm/ 24h < 100 mm |
| Tatizana <i>et al.</i> (1987), | Serra do Mar Cubatão – SP | 1956 a 1986 (30 anos), | 1dia ≥ 100mm 2dias ≥ 150 mm 3dias ≥ 200 mm | Correlação: mm/24h X mm/4 dias $I(mm/dia) = 26303 A_c^{-0,933}$ |
| Au (1993) | Hong Kong | 1982 a 1989 (7 anos) | Não encontrado | Risco elevado para mm/24h ≥ 70mm Risco provável para 50mm < mm/24h |
| Premchitt <i>et al.</i> (1994) | Hong Kong | 1972 a 1992 (20 anos) | Não encontrado | Risco elevado para: mm/h ≥ 70mm mm/24h ≥ 175mm |
| Pun <i>et al.</i> (2003) | Hong Kong | 1984 – 1996 (12 anos) | Não encontrado | Correlação: mm/24h X densidade de deslizamento Probabilidade alta de movimentos de massa: mm/ 24h > 100 mm Observada a influência da acumulada de 15 dias ou 30 dias |

| Referência | Local | Período | Critério para definição de evento pluviométrico | Análises / Correlação |
|---|-------------------------------------|---------------------------------|---|--|
| Instituto de Ricerca per la Protezione Idrogeológica - IRPI (2007) | Diversas regiões do mundo | 1974 a 2008 | Não encontrado | Diferentes de correlações atributos/fatores adotados, equações, gráficos e referências |
| D'Orsi (2011) | Serra dos Órgãos Teresópolis, RJ | 1956 a 1986 (30 anos), | Início: 1h ≥ 20mm Fim: 4h ≤ 5mm | mm/h X mm/24h $I_{(mm/h)} = 620,7 I_{\left(\frac{mm}{dia}\right)}^{-0,71}$ |
| Hassan (2018) | Duque de Caxias, RJ | 2013 a 2016 | Não encontrado | mm/24h X mm/3dias $I_{(mm/24h)} = 45 e^{-0,011A_{\left(\frac{mm}{3 dias}\right)}}$ |
| Dikshit <i>et al.</i> (2020) | Kalimpong, Índia | 2010 a 2016 | Não encontrado | mm/24h x mm/20dias $R_{th(mm/24h)} = 66 - 0,07Ra_{(mm/20dias)}$ |
| Ehrlich <i>et al.</i> (2021) Apud De Oliveira e Silva <i>et al.</i> (2024) | Rio de Janeiro | 1998 a 2002 e 2010 a 2012 | Não encontrado | <div style="border: 1px dashed black; padding: 5px; margin-bottom: 5px;">Sem Evento – NNL* = 0 $I_{(mm/h)} A_{\left(\frac{mm}{96h}\right)}^{0,7} < 1050$</div> <div style="border: 1px dashed black; padding: 5px; margin-bottom: 5px;">Categoria I - 0 < NNL* ≤ 0,2 $1050 < I_{(mm/h)} A_{\left(\frac{mm}{96h}\right)}^{0,7} < 1386$</div> <div style="border: 1px dashed black; padding: 5px; margin-bottom: 5px;">Categoria II – 0,2 < NNL* ≤ 0,4 $1386 < I_{(mm/h)} A_{\left(\frac{mm}{96h}\right)}^{0,7} < 1782$</div> <div style="border: 1px dashed black; padding: 5px;">Categoria III – 0,4 < NNL* $1782 < I_{(mm/h)} A_{\left(\frac{mm}{96h}\right)}^{0,7} < 11575$</div> <p>Onde: *NNL = Número de ocorrência de movimentos de massa por área de suscetibilidade.</p> |

Embora sejam encontradas na literatura algumas propostas de limiar pluviométricos mais recentes (Ehrlich *et al*, 2021, Dikshit *et al.*, 2020; Hassan, 2018), observa-se o desuso dos modelos gráficos. Este fato é justificado pela evolução tecnológica, a partir da qual ferramentas de alto poder computacional se tornaram mais acessíveis e capazes de processar diversos fatores em escala regional, inclusive fatores caracterizadores do espaço físico.

Entretanto, é pertinente ratificar a validade dos modelos gráficos, visto que sua fundamentação tem bases teóricas e apresenta fácil desenvolvimento. Ainda, suas influências, no campo de pesquisa, são representativas, dado que estudos, com abordagens mais modernas, foram desenvolvidos tomando-se este modelo como referência.

2.2 Modelos Probabilísticos – Teorema de Bayes

O estudo da estatística tem 2 (dois) ramos principais: Estatística Descritiva, que envolve organização, resumo e a representação dos dados, e a Estatística Inferencial, que toma partido de uma amostra para obter conclusões sobre uma população. (Larson *et al.*, 2010).

A estatística inferencial, fundamentada em métodos probabilísticos, tem sido aplicada na análise de ocorrência de movimentos de massa. A abordagem bayesiana, por exemplo, é uma maneira particular de formular e lidar com problemas de decisão estatística. Mais especificamente, o teorema de Bayes oferece um método de formalizar conhecimentos a priori e combiná-los com as observações disponíveis, com o objetivo de permitir uma derivação racional de critérios de decisão (Figueiredo, 2004). Desta forma, tal abordagem se difundiu em diversas áreas de estudo, incluindo-se geologia/geotecnia.

Berti *et al.* (2012) considera os atributos intensidade (mm/h) e duração (h) dos eventos de precipitação hipotéticos deflagradores e não deflagradores de movimentos de massa e tomaram partido da aplicação da probabilidade condicional, por meio do teorema de Bayes, que indica a probabilidade de determinado evento A (movimento de massa) ocorrer uma vez que um evento B (evento de precipitação com certa magnitude, que pode ser expresso por meio de acumulada, intensidade e/ou duração) ocorreu.

A título de exemplo, na Figura 12(a) tem-se uma condição ideal, na qual está clara a definição entre duas áreas, representadas por pontos de chuva com e sem movimentos de massa. A grande limitação deste modelo de representação é que ele não caracteriza a maioria dos problemas de movimentos de massa encontrados na realidade, visto que estes se aproximam mais de aspectos demonstrados na Figura 12(b).

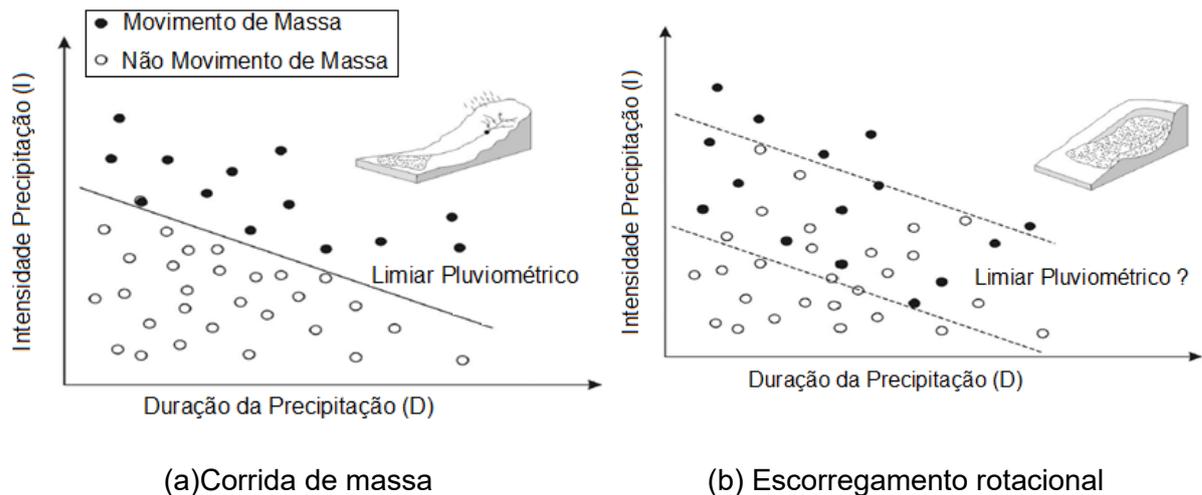


Figura 12 – Limiares de chuva intensidade-duração (Modificado de Berti *et al.*, 2012)

Na Figura 12(b), Berti *et al.* (2012) apresentaram um exemplo em que diferentes respostas (ruptura ou não ruptura) podem ser obtidas a partir da entrada de dados da chuva (intensidade e duração). Neste caso, a definição gráfica de limiar pluviométrico não é clara, fato indicativo de que a abordagem determinística não se apresenta apropriada, quando então é indicado recorrer à abordagem probabilística.

A aplicação do teorema de Bayes resulta na obtenção da probabilidade condicional de determinado evento A (por exemplo, movimento de massa) ocorrer, dado que um evento B ocorreu (por exemplo, evento de precipitação com certa magnitude, expresso por meio de acumulada, intensidade e/ou duração). A expressão é dada pela Equação 3:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3)$$

Onde:

$P(B|A)$ = verossimilhança ou probabilidade condicional de B dado A (a probabilidade de se observar um evento de precipitação de magnitude B quando movimentos de massa A ocorrem);

$P(A)$ = probabilidade a priori de A (probabilidade de um movimento de massa ocorrer independentemente da chuva de magnitude B ocorrer ou não);

$P(B)$ = probabilidade marginal de B (probabilidade de observar uma chuva de magnitude B independentemente da ocorrência ou não de movimentos de massa);

$P(A|B)$ = probabilidade a posteriori ou condicional de A dado que B ocorreu (probabilidade de observar um movimento de massa A quando eventos de precipitação de magnitude B ocorrem).

A aplicação do teorema de Bayes pode ser estendida de modo que se considerem mais atributos (Equação 4). Para o caso da probabilidade condicional aplicada a eventos de precipitação e movimentos de massa, pode-se contemplar na análise uma combinação de par de atributos que representem os eventos de precipitação tais como intensidade, duração, acumulada etc.

$$P(A|B, C) = \frac{P(B, C|A)P(A)}{P(B, C)} \quad (4)$$

Onde a notação $\underline{B, C}$ indica a probabilidade conjunta de que se tenha um certo valor ou um intervalo de valores dos dois atributos. Caso $B \equiv I$ (intensidade) e $C \equiv D$ (duração), a Equação 4 indicará a probabilidade de ocorrência de movimento de massa em resposta a um evento de precipitação pertencente a determinado intervalo de intensidade e duração.

Sistemas de alerta estabelecidos com base no teorema de Bayes apresentam alguns aspectos interessantes, tais como, a flexibilidade de aplicação, a inclusão de variáveis condicionantes e a possibilidade de atualização sistemática, com a introdução dos novos eventos.

Brunetti *et al.*, 2010 compilaram 77 eventos de precipitação (2002-2009), que resultaram em movimentos de massa, para determinar, por meio do método Bayesiano, as condições mínimas de precipitação necessárias para a ocorrência de movimentos de massa na região de Abruzzo, na Itália. Eles observaram que os limiares probabilísticos para a região de Abruzzo são inferiores aos limiares nacionais para Itália e inferiores aos limiares regionais para as regiões do Piemonte e da Lombardia, no norte de Itália, e para a região da Campânia, no sul de Itália. Estas observações conduziram à conclusão de que os movimentos de massa ,na Itália, podem ser desencadeados por condições de precipitação menos severas do que as anteriormente reconhecidas.

Treesa *et al.* (2021) aplicaram o teorema de Bayes no desenvolvimento de modelo empírico que considera 2 (dois) atributos, a umidade do solo e a severidade da precipitação (Figura 13), para análise da probabilidade de ocorrência de movimentos de massa no Distrito de Idukki, na Índia. O objetivo principal daquele estudo é verificar a melhoria de desempenho do modelo a partir da inserção dos efeitos da umidade do solo e para tal adotam a severidade do evento de precipitação representada por 6 (seis) limiares pluviométricos (T1 a T50) e a umidade do solo (%).

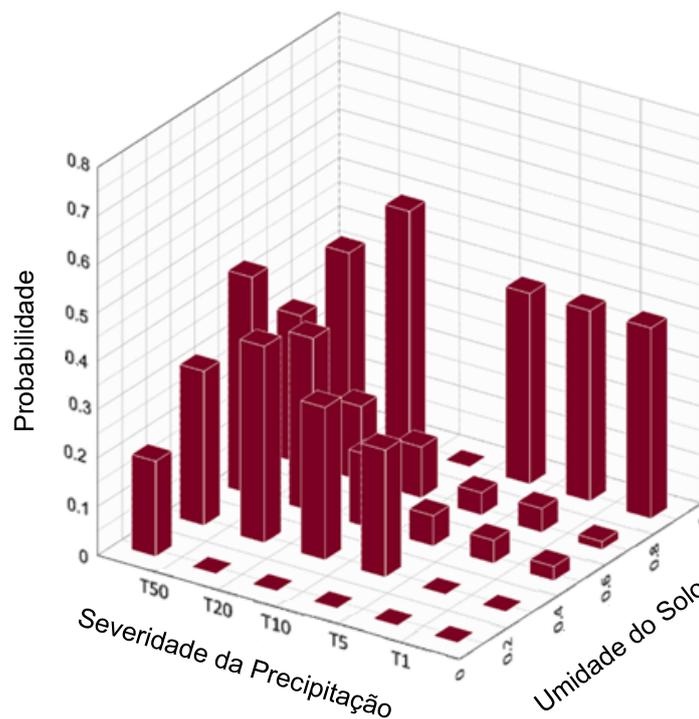


Figura 13 –Análise Bayesiana – Idukki - Índia (Modificado de Treesa *et al.*, 2021)

A partir dos eventos de precipitação deflagradores e não deflagradores de movimentos de massa, foram gerados os limiares de severidade T1, T5, T10, T20 e T50 (Figura 14) por meio do programa computacional proposto por Melillo *et al.* (2018, 2014).

Os limiares de severidade representam a probabilidade de ocorrência de movimentos de massa obtidas a partir dos fatores/atributos duração (h) e acumulada (mm). Quanto maior o grau do limiar, maior é a probabilidade de ocorrência de movimentos de massa. O limiar T50, por exemplo, estabelece um limite de região gráfica acima do qual a probabilidade de ocorrência de movimentos de massa é maior ou igual a 50%.

Os resultados de Treesa *et al.* (2021) mostraram que, quando o conteúdo de umidade antecedente no solo é menor do que 20%, apenas eventos de precipitação severa (T50) se relacionam com desencadeamento de movimento de massa (Figura 13). A conclusão é que a análise probabilística baseada nos atributos severidade e umidade do solo aumentou a previsibilidade do modelo, de modo que o desempenho é representativamente melhor do que o modelo de limiar pluviométrico. O modelo probabilístico resultou na redução da taxa de alarmes falsos (falso-positivo) de 0,28 para 0,08.

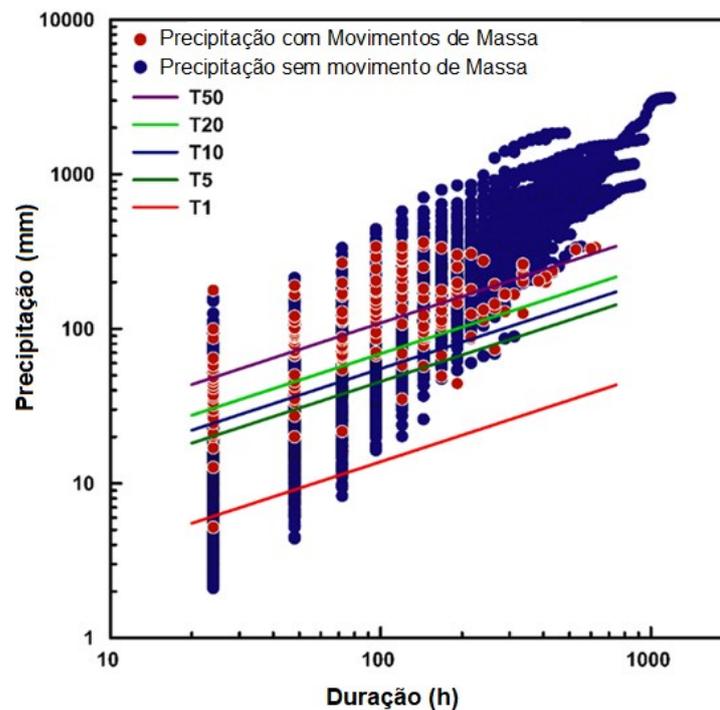


Figura 14 – Limiares de Severidade de Eventos (Treesa *et al.*, 2021)

Zhao *et al.* (2019) desenvolveram, para a Região da Emilia-Romagna, na Itália, estudos similares aos apresentados por Treesa *et al.* (2021) e concluíram que os resultados obtidos com a análise probabilística, a qual considerou a umidade do solo como atributo, representaram as melhores previsões em relação àqueles que utilizaram apenas limiares de severidade. Tal melhoria foi observada pela redução da taxa de alarmes falsos (falsos-positivos) de 0,58 para 0,28.

De modo geral, as abordagens de Zhao *et al.* (2019) e Treesa *et al.* (2021) apresentam aspectos que os destacam, principalmente por incluir na análise probabilística a umidade de solo, do dia anterior à ocorrência do movimento de massa, com propósito de caracterizar a condição do solo em relação à chuva/precipitação antecedente.

Na Tabela 11, tem-se uma compilação das características principais dos trabalhos de Brunetti *et al.*, 2010; Berti *et al.*, 2012; Zhao *et al.*, 2019, Treesa *et al.*, 2021, que realizaram inferência Bayesiana para a determinação de limiares de precipitação.

Tabela 11. Modelos Probabilísticos - Teorema de Bayes

| Referência | Local | Atributos/Fatores |
|-------------------------------|-------------------------------------|--|
| Brunetti <i>et al.</i> (2010) | Abruzzo, Itália | intensidade (mm/h) duração (h) |
| Berti <i>et al.</i> , (2012) | Eventos de precipitação hipotéticos | intensidade (mm/h) duração (h) |
| Zhao <i>et al.</i> (2019) | Emilia-Romagna, Itália | Umidade do solo (%) Limiares de severidade (T1 a T50) |
| Treesa <i>et al.</i> (2021) | Distrito de Idukki, Índia | Umidade do solo (%) Limiares de severidade (T1 a T50) |

2.3 Técnicas de Aprendizado de Máquina

Segundo Alpaydin (2014), estamos na era do *Big Data* graças aos computadores pessoais e ao uso generalizado de meios digitais de comunicação, que nos tornaram consumidores e, também, produtores de dados. Deste modo, a quantidade de dados cresce continuamente e, conseqüentemente, a necessidade de evolução da capacidade para processá-la e transformá-la em conhecimento também é aumentada.

Neste contexto, o aprendizado de máquina (*machine learning*) pode ser considerado um dos campos de crescimento mais acelerado da informática, com aplicações em problemas das mais diversas áreas de conhecimento (Alpaydin, 2014). Por exemplo, a classificação de mensagens de e-mail em spam e em não spam pode ser realizada por meio de uso de técnicas de aprendizado de máquina, dentre outras apresentadas na Figura 15.

A seguir são apresentadas duas definições de aprendizado de máquina consolidadas no campo científico:

“Machine Learning: Field of study that gives computers the ability to learn without being explicitly programmed” (Arthur Samuel, 1959).

“Well-posed Learning Problem: A computer program is said to learn from experience E with respect to some task T and some performance measure P , if its performance on T , as measured by P , improves with experience E .” (Tom Mitchell, 1998).

Como o nome *machine learning* permite intuir e, segundo a definição de Tom Mitchell, o algoritmo necessita de experiências para aumentar o número de acertos, ou seja, para realizar determinadas tarefas com maior confiabilidade.

O cerne do aprendizado está vinculado às experiências disponíveis para treinamento, validação e verificação final ou teste de aderência. Os algoritmos estruturados para desenvolverem o aprendizado são subdivididos em grupos: i) aprendizado supervisionado; ii) aprendizado não supervisionado; iii) aprendizado por reforço e iv) aprendizado semisupervisionado. Este último foi proposto mais recentemente. A Figura 15 mostra alguns exemplos mais comuns de aplicação dos 3(três) primeiros tipos de aprendizado.



Figura 15 – Grupos de “Machine Learning”(Modificado de Machado *et al.*, 2020)

Algoritmos de aprendizado de máquina podem ser utilizados para construção de modelos preditivos, cujo desenvolvimento é feito de modo iterativo. A Figura 16, apresenta, de modo simplificado, um fluxo básico de construção de um modelo, o qual utiliza amostras como dados de entrada e se desenvolve em torno do treinamento, validação e teste.

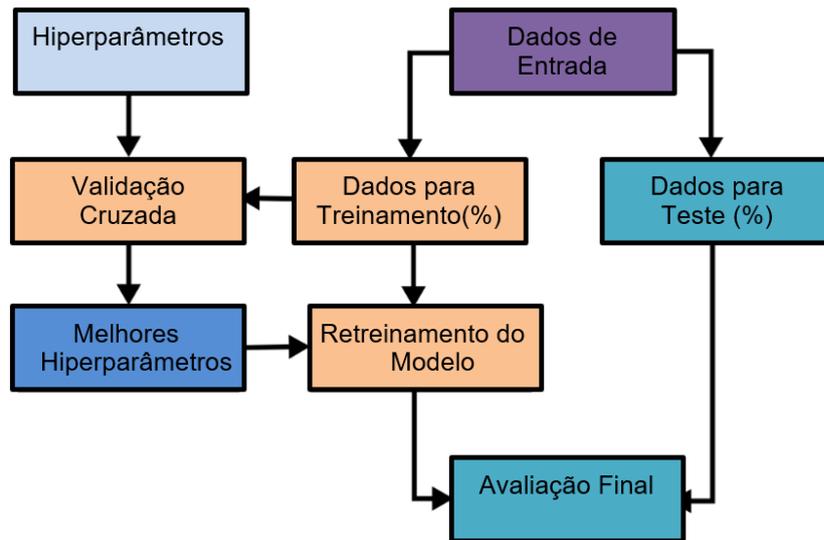


Figura 16 – Fluxo - Construção de Modelo (Modificado de Scikit-Learn,2007)

Nos itens 2.3.1 a 2.3.3, é apresentado com mais detalhes o fluxo básico de construção de um modelo (Figura 16).

2.3.1 Dados de Entrada

Modelos são construídos para realizar tarefas, entre elas previsão/predição, e sua capacidade de acertos se desenvolve com base nas experiências (dados/amostras). Pode-se dizer que as amostras com as quais o modelo tem contato representam as experiências as quais ele é submetido. Logo, evidencia-se a importância e a representatividade da qualidade das amostras para o desempenho de um modelo.

O conjunto de dados de entrada (Figura 16) é constituído por amostras representativas de fenômenos/eventos ocorridos e estudados. Desta forma, dados fidedignos à realidade transmitem aos modelos atributos importantes sobre os fenômenos/eventos. Desta forma, dada sua importância na construção de modelo representativos e úteis, o conjunto de dados de entrada é submetido à fase de pré-processamento. Segundo MIT (2021), em geral o pré-processamento de dados pode ser realizado em 4 etapas:

- I. **Limpeza:** Tratamento de dados ausentes, de valores discrepantes, de registros duplicados e/ou incorretos. Por exemplo, no banco de dados de movimentos de massa havia movimentos cuja confiabilidade da data da ocorrência do movimento era baixa, ou suas coordenadas geográficas resultavam em localização que não pertence a encostas;
- II. **Integração:** Os dados podem se originar de fontes heterogêneas ou pertencer a conjuntos de dados distintos. Esta etapa reorganiza os vários conjuntos de dados em um conjunto único. Por exemplo, integração dos dados de precipitação com os dados de movimentos de massa;
- III. **Transformação:** Os dados podem estar em formatos e/ou unidades diferentes das que são úteis para o pesquisador. Por exemplo, os dados de precipitação disponibilizados pelo banco de dados do Alerta Rio são apresentados em arquivo mensal, no formato “.txt”, em que cada linha representa a precipitação coletada a cada 15 minutos. Entretanto, a concepção do estudo adota precipitação diária (24h);
- IV. **Redução:** Remoção de registros e/ou variáveis redundantes e reorganização dos dados de forma eficiente e “arrumada” para análise, tal como apresentado na Tabela 12, por exemplo.

De modo geral, dados de entrada são representados por um conjunto de exemplares, cada um deles é caracterizado por atributos/fatores. A Tabela 12 exemplifica o resultado da fase de pré-processamento dos dados e, no APÊNDICE A, tem-se o conjunto completo dos dados de entrada utilizados no presente trabalho.

Tabela 12. Modelo - Estruturação de Dados

| Referências | Atributos/Fatores | | | | | | | | Rótulos |
|-------------|----------------------|-------------|-----------------------|-------------|-----------------------|-------------|-----------------------|-------------|------------------|
| | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | | |
| Amostra | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Classe (Binária) |
| 1 | 94 | 12 | 13 | 4 | 6 | 2 | 6 | 2 | 0 |
| 2 | 23 | 9 | 94 | 12 | 13 | 4 | 6 | 2 | 0 |
| 3 | 9 | 6 | 23 | 9 | 94 | 12 | 13 | 4 | 0 |
| 4 | 6 | 5 | 9 | 6 | 23 | 9 | 94 | 12 | 0 |

Dados de entrada podem ou não possuir resultados referenciais (rótulos), como ocorre na Tabela 12. A existência de rótulos (resultado referencial) e seu tipo numérico (contínuo ou discreto) poderão ser orientadores dos grupos e dos tipos de algorítmicos passíveis de serem utilizados. Quando se conhece o resultado/resposta para cada exemplo da base de dados, é possível colocar rótulos, os quais serão utilizados no aprendizado supervisionado. Se os rótulos forem numericamente classificados como contínuos, tem-se como possibilidade a adoção de método de regressão; para rótulos discretos, podem-se aplicar métodos de classificação (Figura 15). Em situações em que não há resultados ou rótulos, recomenda-se a técnica de aprendizado não supervisionado (Figura 15).

2.3.2 Treinamento e Validação

Para realização do treinamento e validação (Figura 16), além da qualidade dos exemplares/amostras, é necessário que o banco de dados contemple um valor representativo de registros, com quantidade suficiente de amostras para que possam ser empregadas exclusivamente na fase de treinamento e validação. A quantidade de dados se apresenta como segundo ponto fundamental para a construção de modelos eficazes. De modo geral, na fase de treinamento e validação, pode-se enumerar as seguintes etapas:

- I. **Segregação de Amostras:** A partir do conjunto total de dados de entrada, são definidas as proporções a serem utilizadas nas fases de treinamento, validação e testes. Não existe diretriz rigorosa quanto à proporção de partição. É possível encontrar grupos de testes que variam de 10 a 30%, enquanto a quantidade remanescente é destinada ao grupo de treinamento e validação (70 a 90%);
- II. **Definição do Algoritmo:** Previamente à realização do treinamento, é necessário realizar a escolha dos algoritmos de aprendizado que serão empregados. Regularmente, tomando-se um mesmo grupo de dados de entrada, são realizados estudos com alguns tipos de algoritmos,. Esta prática é possível graças à disponibilidade de ferramentas computacionais. Na maioria das vezes, a quantidade de atributos/fatores adotados impõe característica multidimensional ao problema. Graficamente, a visualização de distribuições está limitada ao espaço tridimensional. Logo, para casos em que a quantidade de

atributos/fatores é maior do que 3 (três), a observação de padrões é dificultada. Desta forma, a percepção dos tipos de funções matemáticas que melhor representariam o conjunto de dados fica prejudicada. Nestas situações, após identificados o grupo de aprendizado (Figura 15) e, também, o método que melhor se adequa à natureza dos dados e ao tipo de problema em estudo, pode-se tomar partido da diversidade de algoritmos e da disponibilidade de capacidade de processamento das ferramentas computacionais, ambos são vantagens bem-vindas e possíveis de serem exploradas.

- III. **Hiperparâmetros:** Para realização do treinamento e validação é necessária a adoção de hiperparâmetros (Figura 16). De acordo com Yang e Shami (2020), hiperparâmetros são utilizados para configurar os modelos de aprendizado de máquina e devem ser definidos antes do treinamento. Em termos exemplificativos, Alpaydin (2014) indica que hiperparâmetros podem ser a quantidade de árvores em uma Floresta Aleatória (*Random Forest*), a função kernel em Máquina de Vetores Suporte (*Support Vector Machine*), o número de camadas ocultas em um Perceptron Multicamadas (*Multi-layer Perceptron*) etc., como será apresentado com maiores detalhes no item 2.4.1.
- IV. **Validação Cruzada (*Cross-validation*):** Na fase de treinamento e validação, o modelo é aferido para os conjuntos de treinamento e de validação e ambas as métricas são comparadas. O método de validação cruzada (Figura 17) permite a realização desta etapa conjuntamente com a etapa de treinamento e possibilita a segregação das amostras em diversas combinações de grupos de treinamento e validação, com objetivo de averiguar a resposta das métricas e de conduzir à obtenção de modelo com melhor desempenho. Na Figura 17, é apresentado um esquema de validação cruzada, a qual permite a utilização de um mesmo conjunto de dados de formas diferentes, no caso representativo foram adotadas 5 (cinco) combinações/pastas (*k-fold*).

Vallet *et al.* (2016) trazem um ponto interessante de ser abordado, eles observaram interpretação equivocada a respeito da validação cruzada, no que tange à performance do modelo.

Ainda, Vallet *et al.* (2016) afirmam que, mesmo utilizando-se a validação cruzada, não se deve tomar suas métricas como resultado final e orientam que sejam realizados testes com um grupo de amostras com as quais o modelo nunca manteve contato. Tal recomendação também é encontrada na biblioteca Scikit-Learn (2007), no módulo que trata especificamente da validação cruzada.

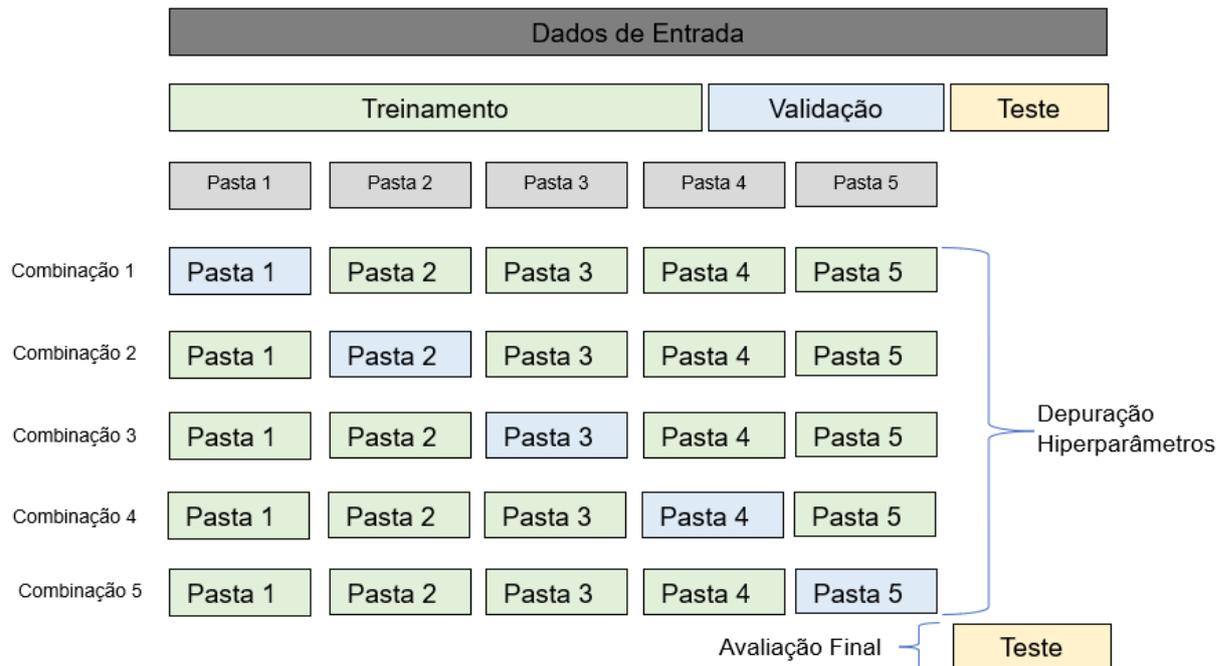


Figura 17 – Validação Cruzada (Modificado de Scikit-Learn,2007)

Além da qualidade e da quantidade de dados, para casos em que se faz uso de algoritmos classificadores, é importante observar o balanceamento das classes, ou seja, verificar se as quantidades de amostras das classes se equiparam.

AL-najjar *et al.* (2021) sinaliza que é comum a existência de desbalanceamento de dados e, neste contexto, comparou algoritmos utilizados para balanceamento de classes e concluiu que a adoção destes métodos, tal como a sintetização de amostras, produz melhores resultados de acurácia, por exemplo. Além disto, o balanceamento proporciona um ambiente propício ao desenvolvimento de treinamentos, principalmente pelo fato de ser comum não haver banco de dados suficiente para explorar a capacidade preditiva dos algoritmos.

O balanceamento das classes é necessário para desenvolvimento do modelo e pode ser realizado por meio de técnicas de redução de amostras da classe majoritária ou de incremento de amostras da classe minoritária.

Ramezankhani *et al.* (2016), Li *et al.* (2022) e Torres *et al.* (2022), por exemplo, desenvolveram modelos classificadores cujo balanceamento (incremento da classe minoritária) foi realizado a partir das amostras destinadas ao treinamento e validação. Entende-se que estes autores buscaram controlar a influência das amostras de testes na fase de treinamento e validação.

Além disso, a IBM (2024) orienta que sejam utilizadas as práticas de incremento da classe minoritária, conforme diretrizes da Imbalanced-Learn (2024). Desta forma, com intuito de reduzir as chances de ocorrência de vazamento de dados (*data leakage*), o incremento por meio de geração de amostras sintéticas (*SMOTE*), por exemplo, deve ser aplicado apenas no grupo de dados destinado a treinamento e validação. Ademais, esta prática corrobora, em certo grau, com as orientações de Alpaydin (2014), que sinaliza a necessidade de realização da segregação de dados de treinamento, validação e teste, de modo que os dados de teste não tenham sido utilizados para treinamento e validação.

2.3.3 Teste

Além da validação cruzada, a aferição da capacidade preditiva do modelo também é realizada por meio de teste (Figura 16) em amostras com as quais o algoritmo nunca teve contato. Os resultados das fases de validação e de teste devem ser aferidos a partir de métricas; isto é, indicadores de desempenho, que refletem sua capacidade de prever/prever eventos.

O uso de métricas apropriadas para aferição dos resultados é tão importante quanto o uso de dados de entrada fidedignos, confiáveis e representativos da realidade. A escolha das métricas depende do tipo de problema que se estuda.

Por exemplo, a adoção de métricas estatísticas (item 2.4.2), obtidas da matriz de confusão (Figura 27), é comum para avaliar o desempenho de modelos desenvolvidos a partir de algoritmos classificadores. Na biblioteca Scikit-Learn (2007), também podem ser encontradas métricas que, usualmente, são utilizadas para aferição do desempenho dos modelos de aprendizado de máquina

As métricas devem ser aplicadas nas duas principais fases de desenvolvimento do modelo, na fase de treinamento e validação e na fase de testes. A comparação entre os valores das métricas obtidas em cada fase pode traduzir características importantes sobre o modelo, como enviesamento/subajuste (*underfitting*) e alta variância/sobreajuste (*overfitting*).

Sobreajuste (*overfitting*) é um comportamento que ocorre quando o modelo está excessivamente alinhado aos dados de treinamento, tal como apresentado na Figura 18 (a). Em outras palavras, o modelo decora os dados de treinamento e perde a habilidade de generalizar, tal como teria se estivesse ajustado Figura 18 (b). Este comportamento é refletido nas métricas, uma vez que modelos sobreajustados tendem a responder bem na fase de treinamento e validação, entretanto apresentam desempenho reduzido na fase de teste.

Subajuste (*underfitting*) é o oposto de sobreajuste e ocorre quando um modelo não aprende o suficiente (Figura 18 (c)). Neste caso, o desempenho é baixo tanto na fase de treinamento e validação, quanto na fase de teste.

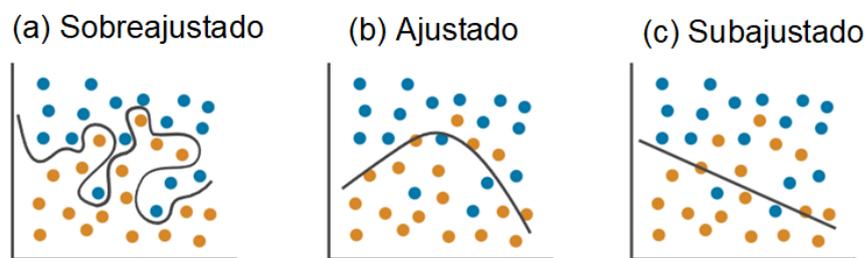


Figura 18 – Sobreajuste e Subajuste - Classificação (Modificado de Mathworks, 2023)

Pode-se dizer que identificar e contornar estes dois extremos do treinamento está no cerne do sucesso de utilização do aprendizado supervisionado. Isto envolve definir os hiperparâmetros do modelo, que refletirão em um desempenho otimizado e em um modelo ajustado. De acordo com a biblioteca Scikit-Learn (2007), hiperparâmetros são passados como argumentos para a construção do modelo.

Arnold *et al.* (2023) afirmam que parâmetros são variáveis que pertencem ao próprio modelo, enquanto hiperparâmetros são variáveis que ajudam a especificar o modelo. Qualquer parte da função que mapeie os dados pode ser considerada um hiperparâmetro. Por exemplo, a Figura 19 apresenta as funções polinomiais (y') e (y''). Os coeficientes destas funções são parâmetros e seus graus polinomiais são considerados hiperparâmetros. Ainda, observa-se que a função polinomial de grau 3 (y'') representa melhor os dados do que uma função polinomial de grau 1 (y'). Isto significa que a função (y'') pode apresentar melhor desempenho no mapeamento dos dados.

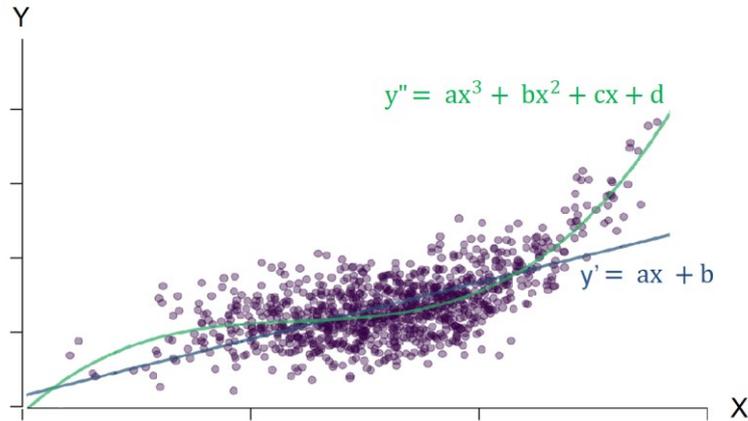


Figura 19 – Hiperparâmetros (Modificado de Arnold *et al.*, 2023)

2.4 Modelos Classificadores -Técnica de Aprendizado Supervisionado

Dentre os três principais grupos de aprendizado de máquina, o aprendizado supervisionado é característico de tarefas de classificação de eventos, tais como o problema de previsão de ocorrência ou não ocorrência de movimentos de massa.

Especificamente em relação aos termos previsão e predição, na literatura, não foi encontrado entendimento pacificado sobre a preferência de uso de um deles em detrimento do outro, embora se observe mais usual o termo predição quando se trata de modelos classificadores. De qualquer forma, entende-se que o termo previsão, por ser mais comum, pode ser melhor compreendido pela maioria dos campos de conhecimento. Sendo assim, o termo predição será adotado quando houver referência específica à classe ou classificação, enquanto o termo previsão será utilizado nas demais situações.

Na modelagem preditiva, um modelo de classificação é utilizado para classificar eventos cujas classes são desconhecidas, ou seja, eventos que não foram utilizados na construção do modelo. A quantidade de classes é definida *a priori*, o que transforma a modelagem num processo de treinamento supervisionado. De modo geral e simplificado, a tarefa de um modelo de aprendizado supervisionado é a construção de uma função, a partir da qual seja possível realizar a predição da classe a que um evento pertence.

Os modelos baseados nesta técnica, permitem a inserção de diversos atributos/fatores e se aplicam a problemas que utilizam dados empíricos. Com isso, se apresenta como alternativa para definição de limiares pluviométricos, abrangendo escala regional.

2.4.1 Algoritmos

Para desenvolvimento da análise objeto desta pesquisa, foram construídos três modelos de classificação baseados em técnicas de aprendizado de máquina: Floresta Aleatória (*Random Forest*), Máquina de Vetores Suporte (*Support Vector Machine*) e Perceptron Multicamadas (*Multi-layer Perceptron*). Tais classificadores têm sido empregados em aplicações diversas e apresentam desempenho satisfatório.

Serão apresentadas, a seguir, breves descrições dos classificadores adotados, as quais objetivam descrever características gerais, de modo simplificado, para fins de distinção entre suas naturezas. Estes classificadores estão disponibilizados para uso livre na biblioteca Scikit-Learn (2007), fundamentada na linguagem *Python*, que possui ampla documentação, incluindo estrutura e orientações de aplicação.

2.4.1.1. Floresta Aleatória - *Random Forest*

Random Forest (RF) é um classificador que combina as previsões de diversas árvores de decisão para estabelecer o resultado mais votado e adotá-lo como a previsão/predição. As árvores que compõe a floresta são geradas tomando-se partido do método de combinação conhecido como “ensacamento” (*bagging*) ou “agregação” (*bootstrap aggregating*).

De acordo com Yeon (2020), este método de combinação seleciona, aleatoriamente e com reposição, e gera diversos subconjuntos a partir das amostras destinadas para treinamento. Cada subconjunto é utilizado para treinar uma árvore (Figura 20). Para alcance da floresta que melhor realiza a classificação, são necessários diversos processos iterativos para depuração/ajuste dos hiperparâmetros, dentre os quais, por exemplo, ocorre a busca pelo número de árvores que irão compor a floresta.

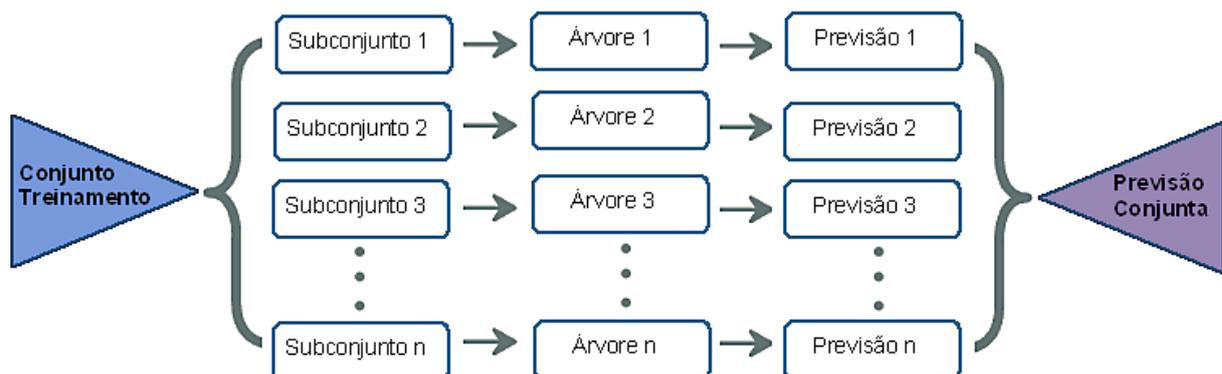


Figura 20 – Floresta Aleatória - Aprendizado Conjunto (Modificado de Yeon, 2020)

Segundo a biblioteca Scikit-Learn (2007), os principais hiperparâmetros a serem ajustados são o número de árvores ($n_estimators$) da floresta e o número de atributos ($max_features$) de cada subconjunto. Quanto maior o número de árvores, melhor, entretanto o tempo de cálculo aumentará. Quanto menor o número de atributos, menor a tendência à variância/sobreajuste (*overfitting*), mas também maior será a tendência ao subajuste (*underfitting*).

Ainda, embora o número de árvores e de atributos sejam considerados hiperparâmetros principais, o algoritmo permite o ajuste de até 20 hiperparâmetros, conforme pode ser verificado na biblioteca Scikit-Learn (2007).

Além da aleatoriedade na seleção das amostras que compõem os subconjuntos, há também aleatoriedade na eleição dos fatores/atributos que serão utilizados para construção das árvores, nem todos os fatores/atributos necessariamente serão utilizados ao mesmo tempo em uma mesma árvore (Figura 21). O objetivo deste método de combinação é gerar uma floresta composta por árvores que possuem baixa correlação entre si e desta forma reduzir a variância ou tendência a *overfitting* do modelo. Uma vez que cada árvore é um modelo, então a floresta representa uma conjunção de modelos que, juntos e por maioria de votos, conduzirão à previsão final.

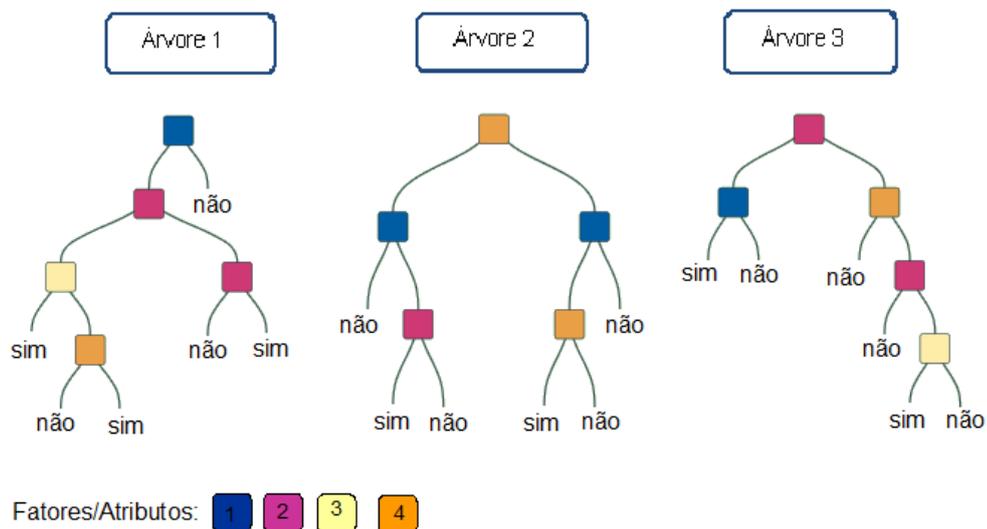


Figura 21 – Floresta Aleatória - Aprendizado Conjunto (Modificado de Yeon, 2020)

A Figura 22 mostra um exemplo de classificação em que a floresta é composta por 3 (três) árvores. Cada árvore realizou sua classificação individualmente e a classificação final foi dada por maioria de votos. Como a maioria das árvores classificou a amostra por classe (0), então esta é a classificação final.

A avaliação do desempenho do modelo, na fase de teste, é realizada a partir da matriz de confusão (Figura 3), por meio da qual tem-se o confronto entre as classes previstas e as classes reais de cada amostra. No caso do exemplo apresentado (Figura 22), o resultado de classe zero indica que o modelo teria previsto a não ocorrência de movimento de massa.

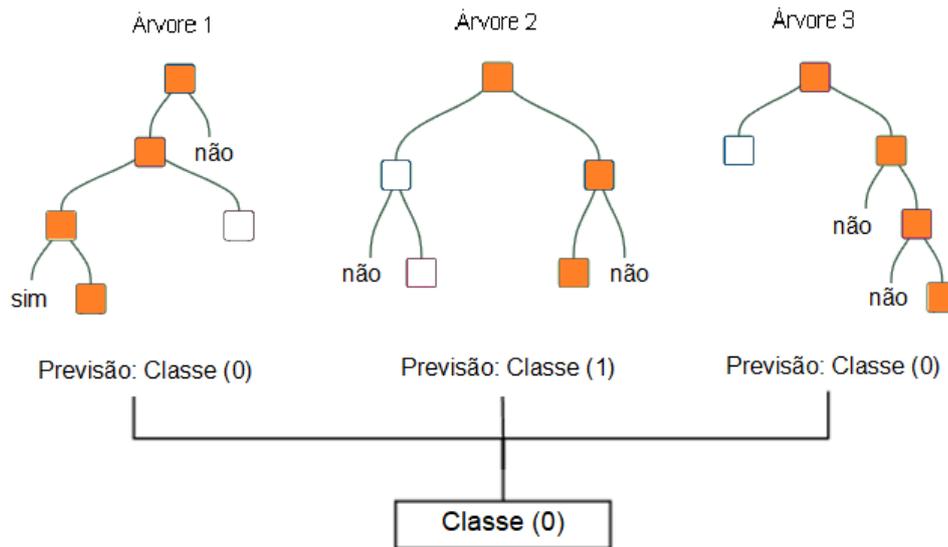


Figura 22 – Floresta Aleatória Genérica (Modificado de Wood, 2020)

Em uma revisão recente sobre a evolução do algoritmo, Abdulkareem *et al.* (2021) o definiu como “um dos mais representativos algoritmos de aprendizado de máquina, reconhecido principalmente pela sua simplicidade e eficácia”. Os autores também ressaltaram o fato deste possuir um vasto repertório de aplicação e com bons resultados em diferentes áreas científicas, como medicina, agricultura, astronomia, etc..

2.4.1.2. Máquina de Vetores Suporte - *Support Vector Machine*

De acordo com Rhys (2020) e com as informações fornecidas pela biblioteca Scikit-Learn (2007), um classificador *Support Vector Machine* (SVM) estabelece um hiperplano ou uma função de segregação de classes (Figura 23). Considera-se que uma boa segregação entre classes é alcançada quando o hiperplano está o máximo possível afastado das amostras de treinamento, pois, em tese, admite-se que quanto maior a largura da margem, menor será o erro de generalização do classificador.

A Figura 23(b) mostra a função de segregação, com 9 (nove) amostras nos limites das margens, chamadas de “vetores de suporte”.

A adoção do classificador SVM é recomendada para casos em que se identificam características gráficas que se adequam a uma solução linear, tal como apresentado na Figura 23(a). Entretanto, para casos em que uma generalização linear para segregação dos rótulos/classes não se apresenta como melhor solução, Bonesso (2013) indica que é possível usar um artifício conhecido como truque do Kernel (Figura 23 (b)). O truque do Kernel implica na utilização de uma função de segregação de classes (hiperplano) que considera o formato de mescla das amostras. Na fase de treinamento e validação do modelo, com objetivo de estabelecer um separador entre as classes, é possível adotar função polinomial, função de base radial ou curva sigmoide, além da função linear.

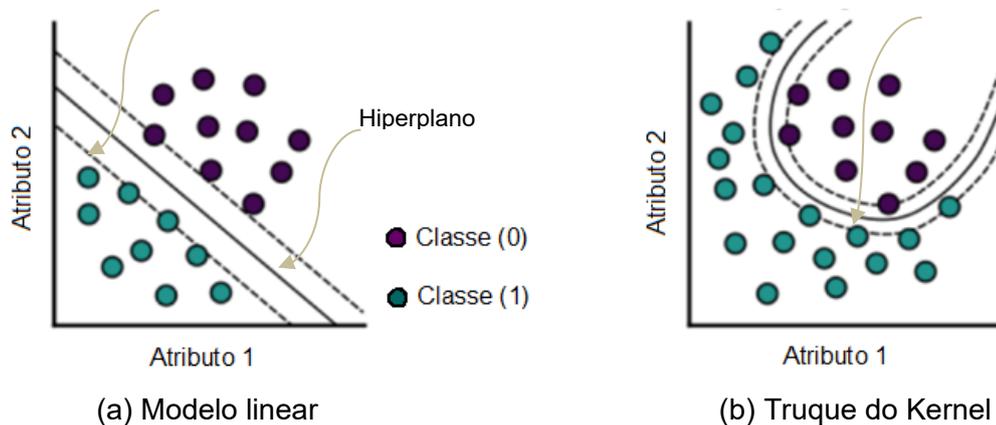


Figura 23 – Método SVM e não Linearidade (Modificado de Rhys, 2020)

Esta função, que é denominada função kernel, é um hiperparâmetro. No total, o classificador SVM permite o ajuste de até 15 hiperparâmetros, conforme pode ser verificado na biblioteca Scikit-Learn (2007). Além da função kernel, o hiperparâmetro de regularização “C também se destaca. Ele realiza a compensação (*trade-off*) entre a classificação correta de amostras de treinamento e a maximização da largura da margem (Figura 23). Segundo a biblioteca Scikit-Learn (2007), para valores maiores de “C”, aceita-se uma largura menor de margem se a função de segregação classificar corretamente todos os pontos de treinamento. Um “C” menor busca uma margem maior, possivelmente ao custo da redução da acurácia do treinamento.

A Figura 24 mostra um exemplo do uso de diferentes funções, em que 03 (três) classes estão associadas a 2 (dois) fatores/atributos. Deste modo, é possível apresentar, por meio de cores do plano de fundo (vermelho, azul escuro e azul claro), as 3 (três) classes de previsão do modelo. Para um mesmo conjunto de treinamento, o formato das regiões vermelha, azul escuro e azul claro é diferente, de acordo com o tipo de função Kernel adotada (linear, base radial ou polinomial). Os pontos representam as amostras utilizadas na fase de teste, as cores de cada ponto representam sua classificação real.

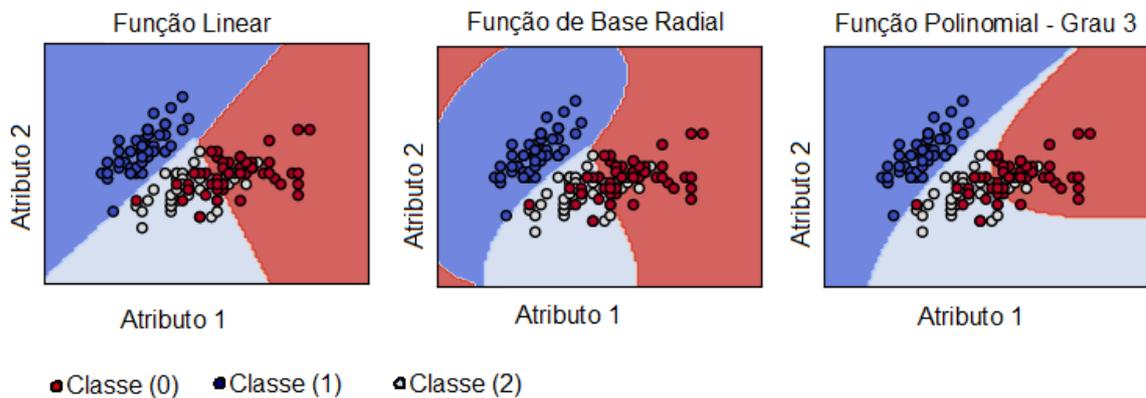


Figura 24 –SVM – Kernel - Funções (Modificado de Scikit-Learn,2007)

A contraposição entre a cor de cada ponto e a do plano de fundo em que ele está inserido permite comparar a classificação real com a classificação prevista pelo modelo. De modo simplificado, a aferição do desempenho de cada modelo é fundamentada nesta contraposição, principalmente nos casos em que, devido a multidimensionalidade do problema, é inviável a realização de sua representação gráfica.

2.4.1.3. Perceptron Multicamadas - *Multi-layer Perceptron*

O classificador Perceptron Multicamadas (*Multi-layer Perceptron* - MLP) é uma Rede Neural Artificial (RNA), a qual é estruturada em camadas de processadores, cujos principais elementos são neurônios. Os dados de entrada, estruturados em forma de atributos, são apresentados para a primeira camada (*input layer*). A última camada, denominada *output layer*, representa o modelo ou a função resultado do treinamento e validação (Figura 25). Entre as camadas de entrada e de saída existem as camadas ocultas, que são constituídas por neurônios.

A quantidade de camadas ocultas, a quantidade de neurônios em cada camada, o tipo de função de ativação, a taxa de aprendizado e o número de iterações, são hiperparâmetros deste classificador. Ainda, segundo a biblioteca Scikit-Learn (2007), para o classificador MLP é possível realizar o ajuste de até 23 hiperparâmetros.

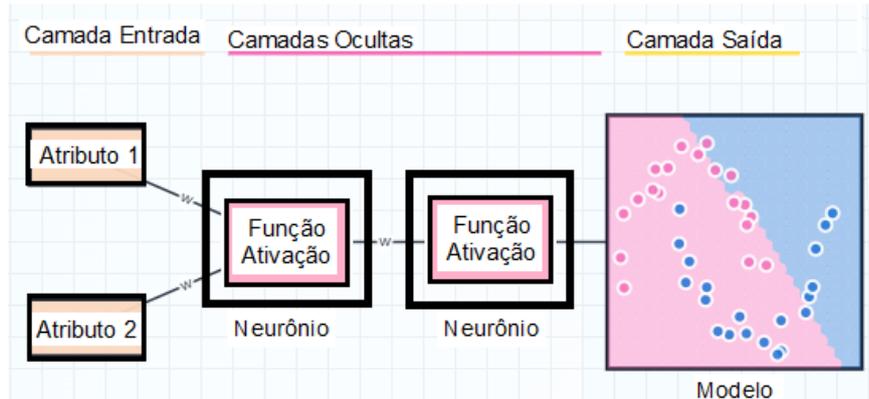


Figura 25 – Rede Neural (Modificado de Wilber, 2023)

De modo geral, em aprendizado supervisionado, os neurônios, por meio da função de ativação, estabelecem uma relação entre os atributos/fatores e os rótulos das amostras utilizadas para treinamento (Figura 26). A combinação destas relações gera a função de saída ou o modelo (Wilber,2023). Segundo Ogunsanya *et al.*, 2023, a função de ativação é usada em aprendizagem para desvendar a não linearidade ou a complexidade em dados.

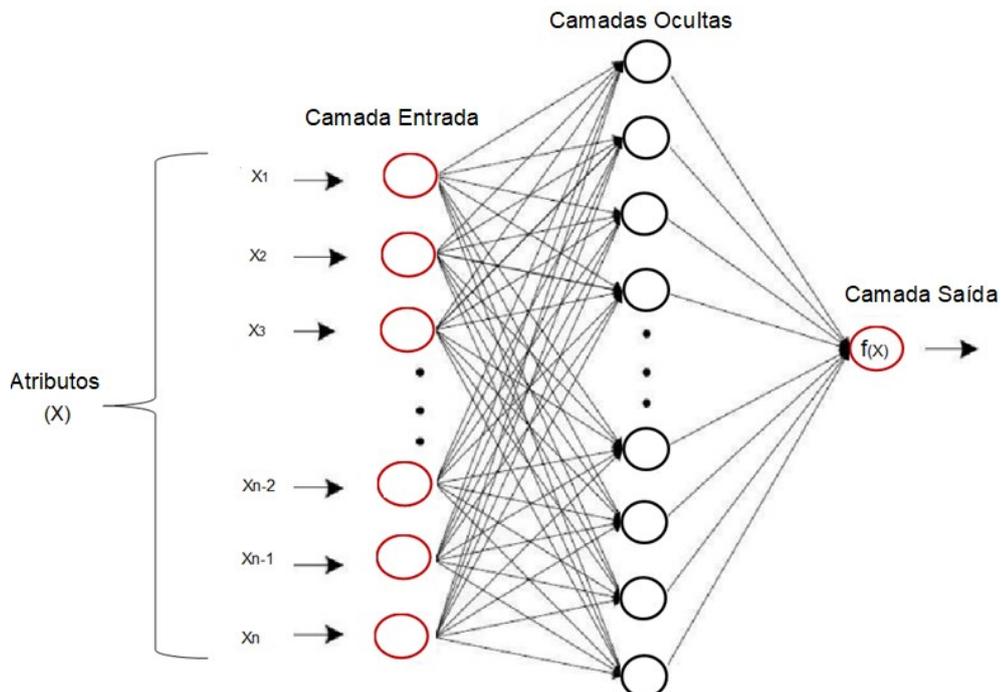


Figura 26 – Perceptron Multicamadas (Modificado de Scikit-Learn,2007)

Para se atingir o modelo que melhor realiza a classificação, são necessários diversos processos iterativos, nos quais, por exemplo, ocorre a busca pelo número de camadas ocultas e/ou pela quantidade de neurônios pertencente a cada camada que irão resultar em melhor desempenho.

2.4.2 Métricas de Avaliação

Métricas são indicadores de desempenho, que fornecem referências para interpretação e comparação de resultados do treinamento, validação e teste dos modelos. De modo geral, as métricas mais difundidas e aplicadas em modelos classificadores estão relacionadas com a matriz de confusão (Figura 27), em que combinações entre os quatro elementos da matriz permitem a aferição de desempenho do modelo sob diferentes óticas. Além delas, a taxa de erro também é utilizada para avaliar a capacidade preditiva de modelos.

Na fase testes, por exemplo, o modelo classifica amostras com as quais nunca teve contato, ou seja, realiza a predição da classe a que cada amostra pertence. Por meio da taxa de erro (Tabela 13) e/ou pela matriz de confusão (Figura 27), as classificações previstas são comparadas com os rótulos ou classes reais das amostras. A comparação entre as classes previstas e as classes reais permite a aferição da resposta do modelo em termos de métricas.

Na Tabela 13, tem-se apresentada a função log do erro, a qual fará parte das análises desenvolvidas nesta tese.

Tabela 13. Métricas de desempenho – Taxa de erro

| Nomenclatura | Descrição | Função | Equação |
|--------------------|---|--|---------|
| Erro (log-loss) | Afere a capacidade do modelo em classificar amostras corretamente | $-\frac{1}{N} \left(\sum_{i=1}^n y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)) \right)$ <p>Onde: N = Número de amostras; y_i = Classe real; $p(y_i)$ = Probabilidade da classe prevista.</p> | (5) |

A função log do erro (*log-loss*), por meio da Equação 5, avalia a compatibilidade entre o valor da probabilidade prevista e o rótulo real da amostra. Este, por sua vez, é 0 ou 1, no caso de classificação binária. Quanto maior a divergência entre a probabilidade prevista e o valor real, maior é a perda logarítmica, ou seja, maior é o erro, cujo intervalo de resultados é $[0, \infty)$.

Na Tabela 14, tem-se um exemplo demonstrativo de aplicação da função log do erro (Equação 5) em que são calculados os erros por amostra e, também, a média do erro do conjunto de amostras. Quanto mais próximo o erro estiver de zero, melhor é o modelo. Um modelo ideal resulta em erro 0 (zero).

Tabela 14. Função log do erro – Exemplo de Referencial Máximo

| Amostra | Classe real (y_i) | Probabilidade prevista ($p(y_i)$) | $y_i \cdot \log(p(y_i))$ (a) | $(1 - y_i) \cdot \log(1 - p(y_i))$ (b) | Log do erro -(a+b) |
|-----------------|-----------------------|-------------------------------------|---------------------------------|---|-----------------------|
| 1 | 0 | 0,1 | 0,0 | -0,045 | 0,045 |
| 2 | 1 | 0,1 | -1,0 | 0 | 1,0 |
| 3 | 0 | 0,1 | 0,0 | -0,045 | 0,045 |
| 4 | 0 | 0,1 | 0,0 | -0,045 | 0,045 |
| 5 | 0 | 0,1 | 0,0 | -0,045 | 0,045 |
| 6 | 0 | 0,1 | 0,0 | -0,045 | 0,045 |
| 7 | 0 | 0,1 | 0,0 | -0,045 | 0,045 |
| 8 | 0 | 0,1 | 0,0 | -0,045 | 0,045 |
| 9 | 0 | 0,1 | 0,0 | -0,045 | 0,045 |
| 10 | 0 | 0,1 | 0,0 | -0,045 | 0,045 |
| Média do erro = | | | | | 0,1405 |

Por se tratar de uma função logarítmica, cujo intervalo é $[0, \infty)$, é necessário estabelecer um referencial máximo aceitável para o erro. Este referencial leva em consideração a proporção real entre classes, ou seja, abarca o desbalanceamento da amostra. Por exemplo, em uma situação de classificação binária, caso o conjunto amostral possua 10% das amostras pertencentes à classe (1), tem-se que a probabilidade de uma amostra qualquer, deste conjunto, pertencer à classe (1) é 10%. Logo admitindo-se esta probabilidade para todas as amostras, pode-se calcular o erro referencial, tal como demonstrado na Tabela 14.

Relativamente à taxa de erro, segundo Vovk (2015), para aferição de desempenho de modelos, a função log do erro (*log-loss*) impõe critérios mais rigorosos, ou seja, é mais seletiva quando comparada à função de erro de Brier, por exemplo. Além disso, entende-se que o rigor destacado por Vovk (2015) está principalmente relacionado às penalidades que a função log do erro impõe quando compara a probabilidade prevista com a classificação real (Tabela 14).

Ademais, na biblioteca Scikit-Learn (2007), estão disponibilizadas ferramentas para cálculo de erro de modelos classificadores, tal como as funções log do erro e de erro de Brier. Também, nesta biblioteca, é indicado que os erro absoluto médio, erro quadrático médio, raiz do erro quadrático médio etc. são aplicados a modelos fundamentados em regressão.

Tratando-se das métricas originadas da matriz de confusão (Figura 27) e utilizadas para avaliação de desempenho de modelos de classificação, elas são índices estatísticos, cujos valores são dados no intervalo [0, 1], utilizados para avaliar e comparar a capacidade preditiva de modelos. Quanto maior o valor numérico da métrica, ou seja, quanto mais próxima de 1,0, maior é a capacidade preditiva do modelo (Bennett *et al.*, 2013, apud Pham *et al.*, 2018).

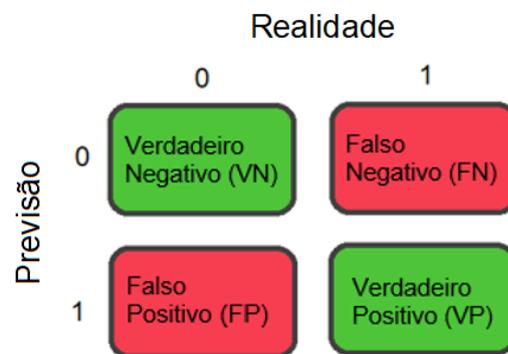


Figura 27 – Matriz de Confusão – Classificação Binária

De modo geral, a resposta do modelo de classificação binária é dada em termos dos numerais **Zero** ou **Um** (Figura 27). Por exemplo, o **Zero** corresponde a previsão não ocorrência e o **Um** corresponde à ocorrência. As classes da realidade seguem a mesma convenção. O modelo ideal é aquele cujas classes previstas corroboram perfeitamente com a realidade. A Tabela 15 elenca as funções das métricas resultantes da matriz de confusão.

Tabela 15. Métricas de desempenho – Matriz de confusão

| Nomenclatura | Descrição | Função | Equação |
|---|---|-------------------------------------|---------|
| Acurácia | avalia a proporção de acertos de modo geral | $\frac{VP + VN}{VP + FP + VN + FN}$ | (6) |
| Precisão | avaliam a capacidade de identificar verdadeiros-positivos | $\frac{VP}{VP + FP}$ | (7) |
| Sensibilidade (ou Taxa de Verdadeiro-Positivo) | | $\frac{VP}{VP + FN}$ | (8) |
| Especificidade | avalia a capacidade de identificar verdadeiros-negativo | $\frac{VN}{VN + FP}$ | (9) |
| Taxa de Falso-Positivo | avalia a capacidade de identificar falso-positivo | $(1 - \text{Especificidade})$ | (10) |

A métrica Acurácia (Equação 6) avalia a proporção de acertos de modo geral, a partir da verificação da quantidade de verdadeiros-positivos (VP) e verdadeiros-negativos (VN) tomados conjuntamente.

As métricas Precisão (Equação 7) e Sensibilidade (Equação 8) focam na capacidade do classificador identificar verdadeiros-positivos, ou seja, representa a resposta do classificador em relação a classe (1) (Figura 27). Por exemplo, em casos relacionados com a vida, tal como exames para identificação de doenças, é comum que se busque maior sensibilidade em detrimento da precisão. Opta-se por reduzir os casos de falsos-negativos, mesmo que esta medida implique na tendência de aumento da quantidade de falsos-positivos. De acordo com o problema enfrentado, possivelmente uma destas duas métricas será tomada como prioridade.

A métrica Especificidade (Equação 9) mantém o foco na não ocorrência (classe 0 - Figura 27) e representa o desempenho em classificar corretamente amostras verdadeiro-negativo. A Taxa de falso-positivo (Equação 10) também mantém atenção na não ocorrência (classe 0 - Figura 27), entretanto representa o desempenho em classificar corretamente amostras falso-positivo.

Existem também índices que avaliam o desempenho a partir da combinação de algumas das métricas da matriz de confusão (Tabela 15). Dentre estes, estão os índices: *AUROC*, F_1 e *GMédia* mostrados na Tabela 16.

Tabela 16. Métricas de desempenho combinadas

| Nomenclatura | Descrição/Função | Equação |
|-----------------|---|---------|
| <i>AUROC</i> | Area sob a Função <i>ROC</i> definida no gráfico sensibilidade ou taxa de verdadeiro-positivo (eixo y) vs taxa de falso-positivo (no eixo x). | - |
| F_1 : | $= 2 * \frac{\text{Precisão} * \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}}$ | (11) |
| <i>GMédia</i> : | $= \sqrt{\text{Sensibilidade} * \text{Especificidade}}$ | (12) |

Na Figura 28 a *AUROC* é estabelecida em função das métricas sensibilidade ou taxa de verdadeiro-positivo (eixo y) e taxa de falso-positivo (no eixo x). Nesta figura, a linha cheia representa a curva *ROC* de um determinado modelo, enquanto a linha tracejada é o referencial que delimita o valor a partir do qual a curva *ROC* representa um modelo sem habilidade classificatória.

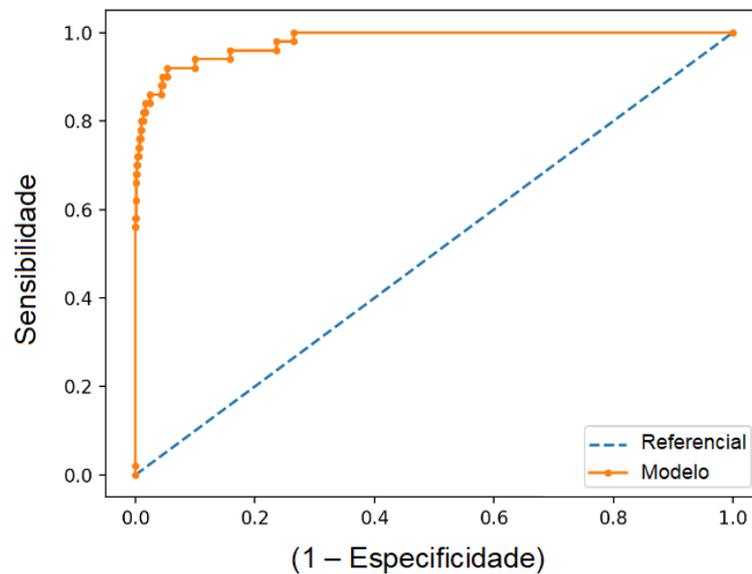


Figura 28 – Modelo Curva *ROC* (Modificado de Brownlee, 2020)

A área sob a curva *ROC*, que é denominada *AUROC*, varia entre 0 e 1. A *AUROC* é uma métrica de desempenho que indica a capacidade do modelo de discriminar casos positivos ou classe (1) de casos negativos ou classe (0). Uma *AUROC* de 0,8 significa que o modelo, na maioria das vezes (80%), classificará corretamente um caso positivo (Draelos, 2019).

Em relação aos resultados da *AUROC*, Polo e Miot (2020) apontam que eles podem ser interpretados da seguinte forma: menor ou igual a 0,6 (falhou); 0,6 a 0,7 (inútil); 0,7 a 0,8 (ruim); 0,8 a 0,9 (bom); maior do que 0,9 (excelente). De outra forma, Draelos (2019) propõe uma interpretação menos segmentada: menor ou igual a 0,6 (inútil); 0,6 a 0,7 (baixo desempenho); 0,7 a 0,8 (bom desempenho); maior do que 0,8 (excelente). De modo geral, observa-se que resultados menores do que 0,7 indicam que ainda há necessidade de melhor desenvolvimento do modelo.

A métrica F_1 (Equação 11) é uma forma de tomarmos as métricas precisão e sensibilidade conjuntamente. Em termos matemáticos, utiliza-se a média harmônica para obter F_1 e seu intervalo de valores possíveis varia entre 0 e 1; quanto maior seu valor melhor a qualidade do modelo.

Simplificadamente, utiliza-se F_1 com intuito de observar a resposta do modelo a partir de uma métrica apenas, em vez de duas métricas separadamente, precisão e sensibilidade. A adoção da média harmônica permite avaliar quando uma das duas métricas está muito baixa, pois quando F_1 possui valor baixo, significa que precisão e/ou sensibilidade possuem valores baixos.

De modo equivalente, a *GMédia* (Equação 12) constitui uma métrica que também adota precisão e sensibilidade conjuntamente e seu intervalo de valores possíveis varia entre 0 e 1. Entretanto a função para cálculo da *GMédia* toma as operações matemáticas raiz quadrada e produto, quando a *GMédia* apresenta valor baixo é sinal de que precisão e/ou sensibilidade possuem valores baixos.

2.4.2.1. Limiar entre Classes

Métricas são adotadas tanto na fase de treinamento e validação, quanto na fase de testes. Na fase de teste, por exemplo, o modelo treinado realiza a previsão de classificação das amostras. Caso os dados de entrada apresentem apenas duas classes (0 e 1), trata-se de problema de classificação binária, caso haja mais classes (0,1,2...n), tem-se um problema de multiclases.

Embora os resultados possam ser apresentados em forma de rótulos de classe (0,1,2...n), regularmente toma-se o resultado probabilístico de um classificador como referência. Esta característica contextualiza o reconhecimento de algoritmos classificadores como geradores de modelos probabilísticos de classificação.

A Figura 29 apresenta um exemplo, em que o resultado de modelo classificador qualquer fornece uma distribuição probabilística de duas classes, nuvem (0) e avião (1). Nela é possível observar que, no intervalo de 0,2 a 0,8, existe uma sobreposição entre as classes (0) e (1).

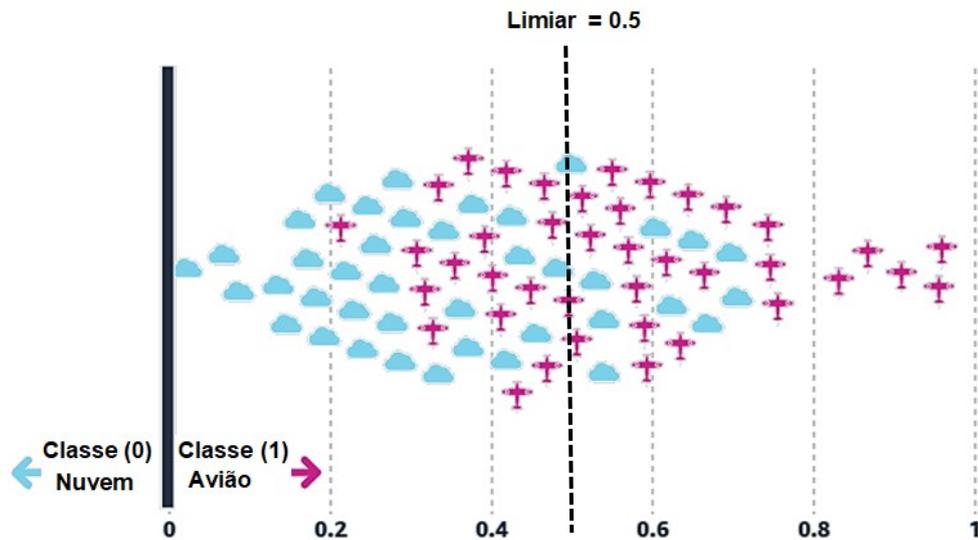


Figura 29 – Distribuição de Classes Binárias – Exemplo (Modificado de Wilber, 2022)

O mesmo tipo de análise poderia ser representada a partir de uma distribuição probabilística de classes binárias, como mostrado na Figura 30. Admitindo que a curva azul representa a classe nuvem (0) e que a curva rosa representa a classe avião (1), a região de sobreposição entre classes, do intervalo 0,2 a 0,8, estaria mais bem evidenciada.

A existência desta região de sobreposição impõe a necessidade de se adotar limiar de segregação entre classes, a partir do qual, automaticamente, serão estabelecidas as regiões de falsos-negativos (FN), à esquerda abaixo da curva tracejada rosa, e de falso-positivo (FP), à direita abaixo da curva tracejada azul. Na Figura 29, por exemplo, o estabelecimento do limiar em 0,5, que é muitas vezes adotado como padrão, indica que haveria 10 falsos-positivos, situação em que nuvens (0) são classificadas como avião (1).

Em um cenário ideal, o classificador é capaz de segregar completamente as classes, caso em que a *AUROC* seria igual a 1, ou seja, o classificador atingiu pleno desempenho em inferir a classe de pertencimento das amostras (Figura 31).

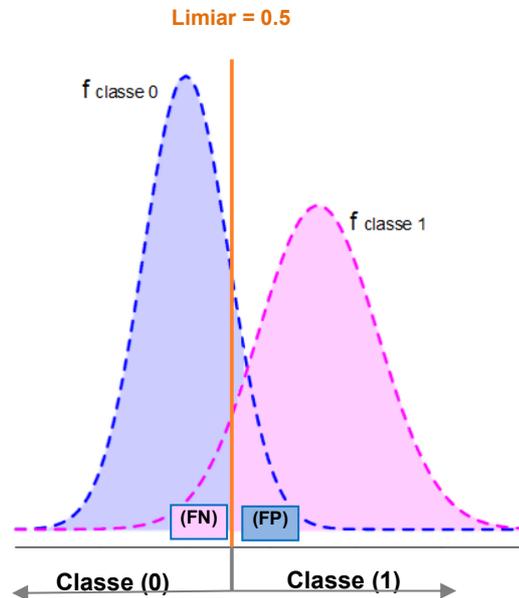


Figura 30 – Ilustração de Distribuição de Classes Binárias

A *AUROC* é uma maneira útil de avaliar a capacidade preditiva do modelo por meio das amostras de teste (IBM, 2021). Ainda, García *et al.*(2021) indicam que a *AUROC* expressa numericamente o resultado diagnóstico do teste, uma vez que ela estima a probabilidade de uma amostra aleatória, cuja classe real é (1), ter um valor mais alto do que uma amostra aleatória cuja classe real é (0).

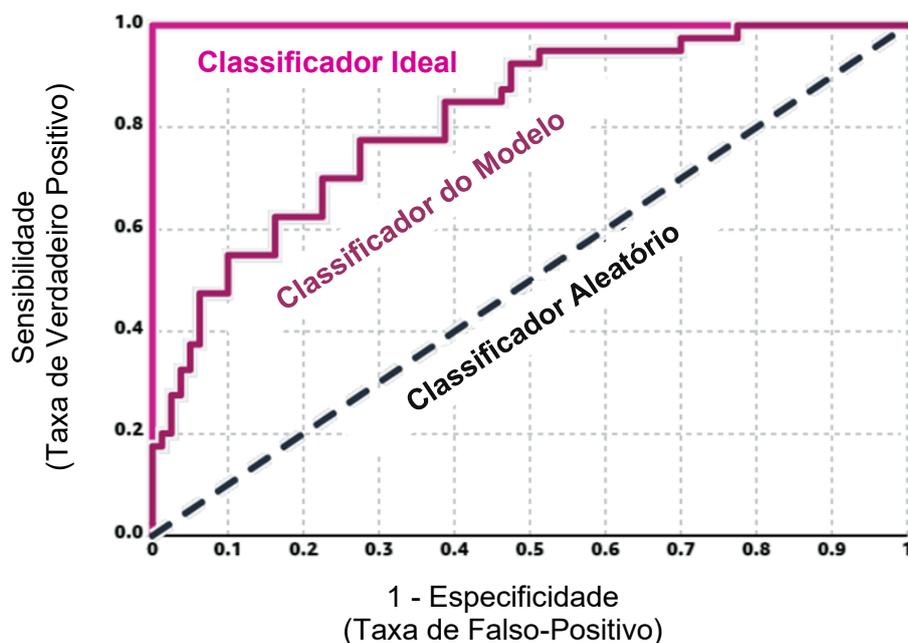


Figura 31 – Curva ROC (Modificado de Wilber, 2022)

O pior cenário é quando as duas classes se sobrepõem completamente, esta circunstância pode ser representada pela linha tracejada preta na Figura 31, situação em que a *AUROC* é igual ou menor do que 0,5. Este cenário implica em interpretar que a capacidade de inferência do classificador não agrega informação, pois corresponde a uma inferência aleatória, em que, no caso binário, a probabilidade de uma amostra pertencer a uma das duas classes é 0,5 ou 50%.

Quanto menor a região de sobreposição entre classes, melhor a capacidade do classificador em realizar inferências e o valor da *AUROC* é tomado como indicador desta habilidade. Para melhor compreensão, Rogozhnikov (2015) e Wilber (2022) ofertam modelos interativo de manuseio da curva *ROC* em combinação com as distribuições das classes, que permite vislumbrar o modo como a distribuição das classes, seus formatos e suas sobreposições afetam o resultado da *AUROC*.

Cada ponto da curva *ROC* do modelo (Figura 31) é representado a partir da variação de posição do limiar (Figura 29). Pode-se, inclusive fixar o limiar na melhor combinação das variáveis representadas nos eixos x e y da curva. Mandrekar (2010) entende que a designação do limiar de segregação entre classes pode ser arbitrado em relação aos resultados de teste. Tustumi (2022) afirma que a escolha do limiar otimizado deve ser realizada com base no que se espera de desempenho real do modelo, baseado no seu desempenho de teste.

Desta forma, a definição do critério de eleição da posição do limiar fica a cargo do entendimento dos analistas do caso, que definem, com base nos resultados de teste, a métrica que melhor representa o objetivo que se espera alcançar com o modelo. Por exemplo, é possível que se opte por reduzir falsos-negativos, como referência para estabelecimento do limiar otimizado.

Segundo Habibzadeh *et al.* (2014), os critérios mais comuns para determinação do limiar otimizado da curva *ROC* originada do teste são: *G*média (Equação 12), que representa o ponto da curva *ROC* onde a sensibilidade e a especificidade são iguais; Máximo índice Youden, obtido a partir da diferença entre sensibilidade (Equação 8) e a taxa de falso positivo (Equação 10); Métodos baseados em análise de decisão bayesiana, em que a probabilidade a posteriori de uma doença depende da probabilidade a priori da doença e do resultado do teste.

Sendo assim, considerando-se os trabalhos de Mandrekar (2010), Tustumi (2022) e Habibzadeh *et al.* (2014), observa-se que não existe um critério específico para definição do limiar otimizado, enquanto uns buscam uma aplicação prática expedita, outros requerem desenvolvimento estatístico/probabilístico mais aprofundado. Entretanto, todos eles utilizam os resultados do grupo de teste. De qualquer forma, cabe a observação de que estudos sobre a posição do limiar otimizado não são temas comuns, recorrentes ou descritos em detalhes nas publicações.

Adicionalmente, por padrão, os modelos criados a partir das ferramentas disponibilizadas pela biblioteca Scikit-Learn (2007) adotam limiar igual a 0,5 (Figura 29). Entretanto, pode-se, por exemplo, estabelecer, a partir da curva *ROC* e da *GMédia*, o limiar otimizado que implica na melhor combinação entre as taxas de falsos-positivos (x) e de falsos-negativos (y).

É importante observar que este limiar estabelece o limite entre classes, ou seja, a posição do limiar afeta diretamente o resultado da matriz de confusão. Logo, é a partir dele que ocorre a geração de falsos-positivos (x) e de falsos-negativos (y).

No caso de risco de movimento de massa, por exemplo, entende-se que o mais importante é garantir a integridade da vida humana. Assim sendo, a opção por um limiar que resulte em incremento do número de falso-positivo se apresenta como uma alternativa mais segura. Porém, quando em excesso, falsos-positivos tendem a gerar descrença no sistema de alerta.

Lucchese (2022) caracteriza este limiar em 0,5 como aleatório e aborda a necessidade de se estabelecer um critério para definição do limiar adotado. Em seu trabalho é adotado limiar que resulta no maior valor de acurácia. Entretanto, pelo fato de que a métrica Acurácia (Equação 6) considera o número de acertos em geral, e de que, conseqüentemente, um valor alto de acurácia não necessariamente significa que o modelo possui bom desempenho. Acredita-se que adotar um limiar otimizado que reduz a taxa de falsos-negativos pode ser uma boa opção.

De modo geral, a definição dos tipos de métricas deve ocorrer com intuito de amplificar nuances e permitir melhor análise da adequação do modelo. Por exemplo, se existir preocupação com existência de falsos-negativos, deve-se avaliar os resultados da sensibilidade do modelo.

2.4.3 Susceptibilidade a Movimentos de Massa

A ciência de dados tem sido adotada no desenvolvimento de modelos para antecipação de resposta comportamental do meio físico, principalmente àqueles cujo propósito é atuar na mitigação dos efeitos de desastres relacionados a fenômenos naturais como precipitação, terremotos, furacões etc.

Técnicas de aprendizado de máquina conjugadas com Sistema de Informações Geográficas (SIG), são tecnologias de grande importância para identificação de áreas suscetíveis aos movimentos de massa e permitem a integração de variáveis geológicas, pedológicas, geoambientais, geomorfológicas, geomorfométricas e climatológicas na construção de modelos (Bispo *et al.*, 2011).

De maneira geral, observa-se a tendência de uso técnicas de aprendizado de máquina para geração de mapas de susceptibilidade, cada qual com sua particularidade em relação aos dados de entrada, à definição de modelos de algoritmos e à região de estudo. Entretanto, de modo geral, muito similares quanto à metodologia utilizada e principalmente com relação às métricas adotadas. Este conglomerado de trabalhos similares foi alvo do artigo de Reichenbach *et al.*(2018).

Com a finalidade de compilar os trabalhos desenvolvidos para avaliação de susceptibilidade a movimentos de massa, Reichenbach *et al.*(2018) analisou 565 artigos publicados entre 1983 a 2016. Para cada artigo foram observadas 31 categorias/subcategorias de informações, incluindo região/extensão do estudo, tipo/número de deslizamentos de terra, tipo de inventário e período coberto, tipos de variáveis, modelo de análise utilizado e método de avaliação de desempenho do modelo. A compilação de Reichenbach *et al.*(2018) conduziu à observação da existência de viés geográfico dos artigos publicados, uma vez que a maioria dos estudos de susceptibilidade ocorrem na China, Índia, Itália e Turquia e que poucos pertencem às regiões da África, América do Sul e Oceania.

Mapas de susceptibilidade refletem, no espaço físico, a probabilidade de ocorrência de movimentos de massa inferida a partir de modelos que adotam amostras representadas por uma série de atributos. Tratando-se de um problema de classificação, estas amostras devem possuir atributos que caracterizam tanto os locais de ocorrência, cujo rótulo é classe (1), quanto os locais de não ocorrência de movimentos de massa, com rótulo classe (0).

Neste contexto, a respeito da parcela de amostras de não ocorrência de movimentos de massa, Lucchese (2022) indica que a caracterização destas amostras é sensível, principalmente por se respaldarem em atributos/fatores que descrevem o espaço físico onde não houve movimentos de massa. Corroborando-se com o posicionamento de Lucchese (2022), entende-se que há dois aspectos principais que devem ser pontuados para escolha do local que será representado por amostra de não ocorrência de movimento de massa.

Primeiro, para todo o período em estudo, deve-se haver certeza, ou maior grau de certeza possível, de que não houve movimento de massa na localidade admitida por classificação (0). Isto implica em avaliar, para cada data do intervalo temporal em estudo, banco de imagens. Admitindo-se que tais registros de imagens de satélite existam e que possuem qualidade/resolução suficiente que permita destacar mesmo um pequeno movimento de massa. Em segundo lugar, considerando-se que é necessário incorporar ao conjunto de dados de entrada amostras representativas, entende-se complexa a definição de os critérios para eleição de pontos de não movimento de massa. Estes dois aspectos explicitam as dificuldades observadas de se estabelecer amostras caracterizadoras dos pontos de não ruptura.

Ademais, quando as análises agregam atributos/fatores que ocorrem no tempo, além daqueles estabelecidos no espaço, amplifica-se o grau de complexidade para estabelecimento dos pontos de não ruptura. A precipitação, por exemplo, é um fenômeno que, fixando-se a região de observação, ocorre no tempo. Caso a precipitação fosse adotada como atributo/fator com objetivo de geração de mapa de suscetibilidade, para fins de composição das amostras de não ruptura, seria necessário estabelecer uma combinação entre o evento de precipitação e as características físicas de cada ponto, de modo que se possa afirmar que, para aquelas características espaciais e o evento de precipitação considerado, não ocorre movimento de massa.

Além disso, a Tabela 17 resume alguns trabalhos na área geotécnica cuja abordagem de análise é realizada por meio de técnicas de aprendizado de máquina.

Tabela 17. Técnicas de Aprendizado de Máquina em Geotecnia/Geologia

| Referência | Objetivo do modelo | Região | Atributos/fatores | Modelo | Métrica |
|---------------------------------|---|-------------------------------|---|--|---|
| Montoya (2013) | Gerar de mapa de susceptibilidade de | Medellín, Colômbia | Inclinação do talude Precipitação | Redes Neurais Artificiais (ANN) | Erro Quadrático Médio |
| Micheletti <i>et al.</i> (2014) | Gerar de mapa de susceptibilidade de | Canton Vaud, Suíça | Altitude Inclinação do talude Umidade solo | Máquina de Vetores Suporte (SVM) Redes Neurais Artificiais (ANN) Floresta Aleatória (RF) | AUROC |
| Bordoni <i>et al.</i> (2018) | Estimar a umidade de solo para estudos de estabilidade de taludes | Oltrepò Pavese, Itália | Temperatura do ar Umidade do ar Radiação solar líquida Velocidade do vento Precipitação | Máquina de Vetores Suporte (SVM) | Erro Absoluto Médio; Erro Quadrático Médio |
| Botero (2018) | Estimar o perfil de poropressão | - (Dados Artificiais) | Precipitação Tipo de solo Declividade Profundidade do lençol Profundidade da superfície potencial de deslizamento | Redes Neurais Artificiais (ANN) | Erro Quadrático Médio |
| Zhang <i>et al.</i> (2021) | Estimar deslocamentos, para previsão de movimentos de massa | Three Gorges Reservoir, China | Precipitação Nível do reservatório | Máquina de Vetores Suporte (SVM) | Erro Absoluto Médio; Erro Quadrático Médio |
| Paliwal <i>et al.</i> (2022) | Estabilidade de taludes | Himalaia | Parcela coesiva Ângulo de atrito Ângulo do talude Módulo de Young Espessura de solo residual | Redes Neurais Artificiais (ANN) | Raiz do Erro Quadrático Médio |

| Referência | Objetivo do modelo | Região | Atributos/fatores | Modelo | Métrica |
|-----------------|-------------------------------|--|---|---------------------------------|---------|
| Lucchese (2022) | Gerar mapa de suscetibilidade | Serra Geral (Rio Grande do Sul e Santa Catarina) | Aspecto Elevação Sombreamento Logaritmo natural da Acumulação de fluxo Curvatura plana Curvatura em perfil Declividade Comprimento do aclave e Fator de declividade Índice de Umidade Topográfica Profundidade de vale Distância vertical até a rede de drenagem | Redes Neurais Artificiais (ANN) | AUROC |

Em contraste à utilização de variáveis apenas do meio espacial para geração de mapa de suscetibilidade, tem-se publicações que inserem a precipitação como fator/atributo, como é o caso de Pham *et al.* (2018), que considera a precipitação, em formato de mapa de precipitações médias anuais, para geração de mapa de suscetibilidade. Na Figura 32 é apresentado o fluxograma de desenvolvimento do estudo de caso de Pham *et al.* (2018).

Além de adotar a precipitação, seu trabalho se destaca pela estrutura de organização, pela capacidade de compilação de informações e pela didática na apresentação das análises. Desta forma, considerou-se pertinente detalhar o trabalho de Pham *et al.* (2018) e descrever as fases de construção de seu modelo e indicar a métrica adotada para avaliação de desempenho.

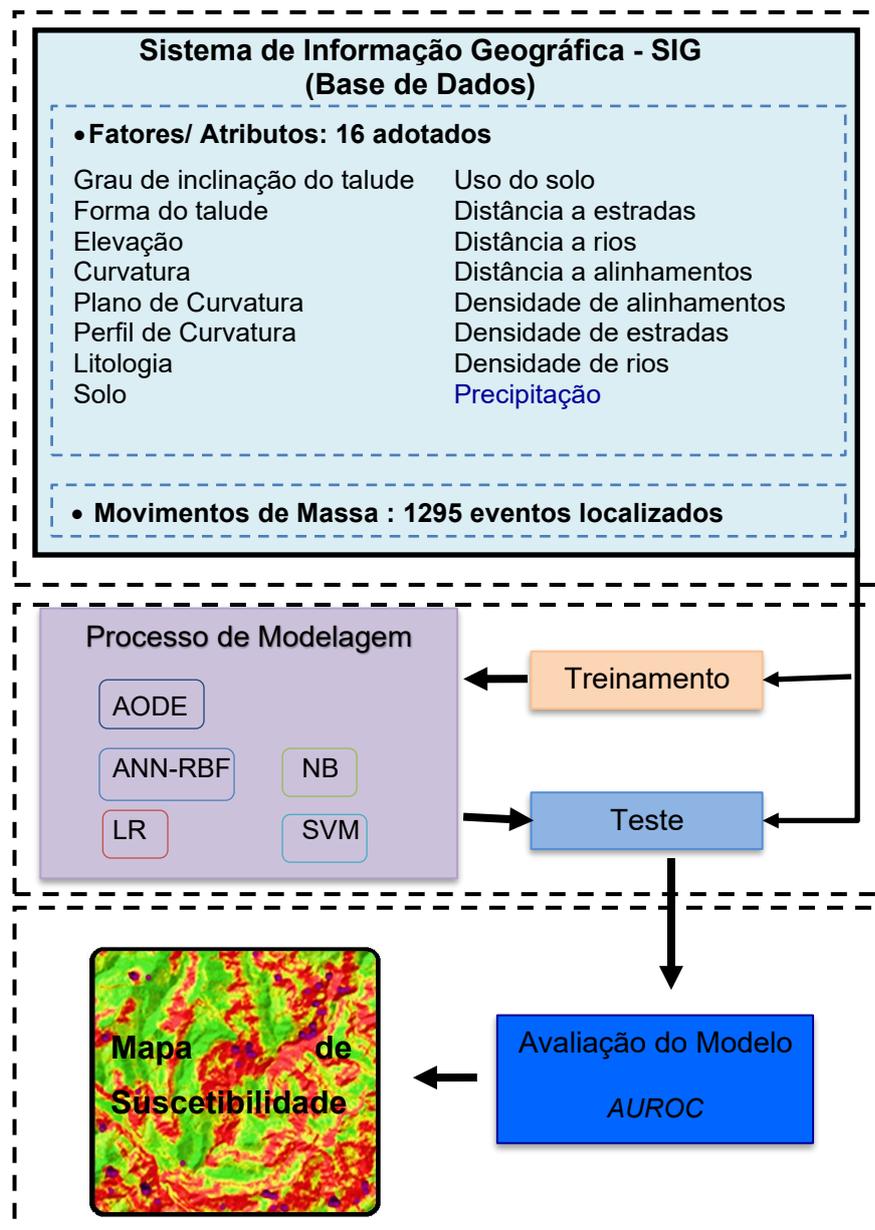


Figura 32 – Fluxograma.(Modificado de Pham *et al.*, 2018)

2.4.3.1. Tratamento de Dados (Pham *et al.* , 2018)

Os autores adotaram um banco de dados com 1295 eventos/exemplares de movimento de massa ocorridos na região de Pauri Gahwal, Uttarakhand, Índia. Por meio de imagens do Google Earth foram definidos os pontos de ocorrência e de não ocorrência dos movimentos e, tomando-se partido do Sistema de Informação Geográfica (SIG), foram utilizados 16 (dezesesseis) atributos/fatores (Figura 32). Entretanto, não foi abordado o critério de definição dos pontos de não movimentos de massa e, também, não houve indicação da localização destes nas imagens apresentadas no artigo (Figura 34).

2.4.3.2. Treinamento e Validação (Pham *et al.* , 2018)

Para treinamento foram adotados 70% das amostras de eventos de movimento e de não movimento de massa, enquanto a validação utilizou 30% das amostras. Os algoritmos classificadores (Figura 33) utilizados são:

- AODE –Estimador Médio de uma dependência (Averaged One-Dependence Estimators)
- SVM - Máquina de Vetores-Suporte (Support Vector Machine)
- LR - Regressão Logística (Logistic Regression)
- ANN-RBF - Redes Neurais com Função de Ativação de Base Radial (Radial Basis Function Neural Network)
- NB - Algoritmo Fundamentado no Teorema de Bayes (Naive Bayes)

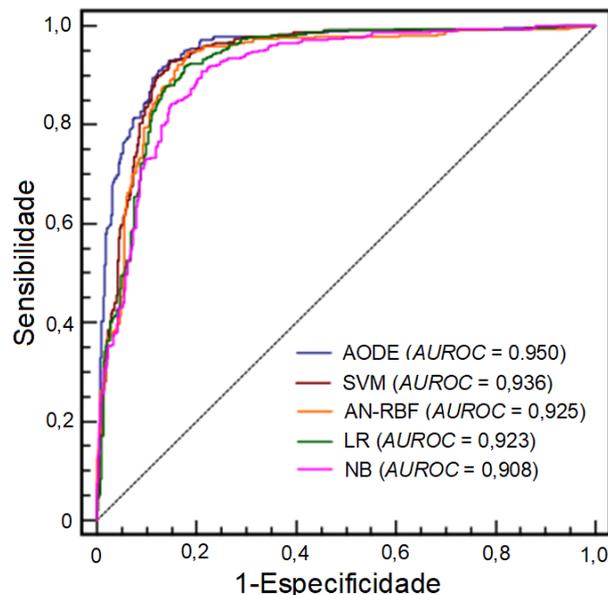


Figura 33 – Validação com a *AUROC* (Modificado de Pham *et al.*, 2018)

Na validação houve a verificação de sua aderência em relação ao grupo de treinamento. A Figura 33 mostra, para o conjunto de dados destinado à validação (30%), a curva *ROC* obtida em todos os modelos. Observa-se que o modelo AODE tem o melhor valor de *AUROC* = 0,950; sendo, portanto, este foi eleito o mais adequado para a avaliação da susceptibilidade em relação à área de estudo.

2.4.3.3. Teste (Pham *et al.* , 2018)

Embora os autores tenham desenvolvido trabalho que pode ser tomado como referências quanto ao roteiro de aplicação de técnicas de aprendizado de máquina conjuntamente com análises de movimentos de massa em escala regional, não ficou clara a efetiva realização de testes com dados completamente desconhecidos pelo modelo, prática que conduz a maior confiabilidade dos resultados de desempenho de modelos. Na Figura 34 é apresentado o mapa de suscetibilidade desenvolvido.

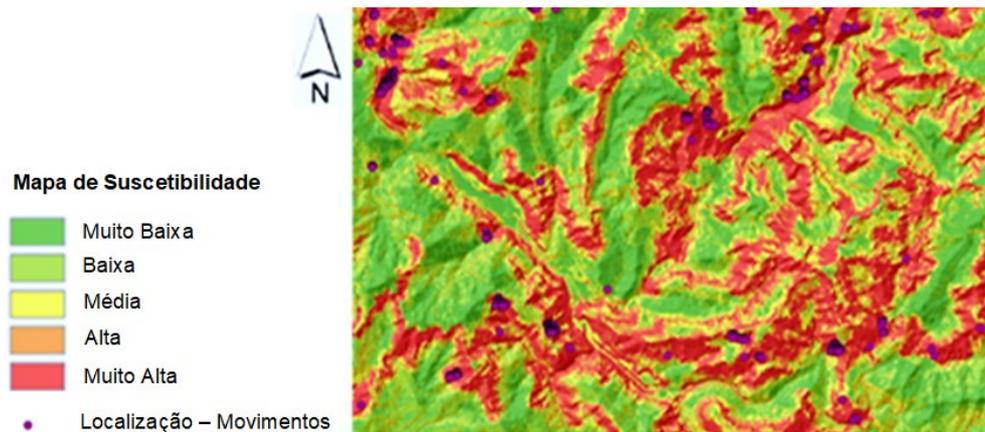


Figura 34 – Mapa de Suscetibilidade (Pham *et al.*, 2018)

Apesar de a chuva/precipitação ter sido considerada um fator/atributo, os autores indicaram que a precipitação mostrou pouca influência na geração do mapa. A análise de seu trabalho conduz ao entendimento de que este resultado está, provavelmente, relacionado ao formato em que a precipitação foi inserida, sem relação temporal com os eventos de movimentos de massa.

A combinação de fatores espaciais com fatores que ocorrem na unidade temporal não é trivial, é necessário que seja possível estabelecer uma conexão no tempo e no espaço que relacione o evento estudado. Por exemplo, a inserção de precipitação deve necessariamente resguardar uma relação de causa/consequência com a deflagração de movimentos de massa, para isto é preciso se certificar de haver correspondência temporal entre cada movimento de massa e o evento de precipitação que o causou. Neste cenário, é mandatório existir banco de dados abrangente e confiável que registre as ocorrências.

Ademais, o desenvolvimento, validação e testes de modelos requer estabelecimento de métricas apropriadas e capacidade de interpretação dos resultados.

Para casos em que há mais do que duas classes, tal como ocorre com os mapas de suscetibilidade, que possuem em média de 3 a 5 classe, ou seja, não adotam classificação binária, esta interpretação se torna mais complexa. Entende-se que esta complexidade é o motivo pelo qual a métrica mais usual é a *AUROC*, havendo, em raros casos, a apresentação explícita de métricas como sensibilidade e precisão.

3 DESENVOLVIMENTO DO MODELO

No Brasil, há registros da utilização de dados de precipitação para inferência sobre a ocorrência de movimentos de massa desde meados dos anos 1970 (item 2.1). Na cidade do Rio de Janeiro, o Sistema Alerta Rio, em operação desde 1996, é fundamentado em atributos caracterizadores de precipitação. O Sistema estabelece probabilidades de ocorrência de movimentos de massa (Tabela 9), com base em correlações empíricas, construídas a partir da combinação de registros de pluviometria e da identificação das ocorrências.

No presente trabalho, foram adotados atributos de precipitação obtidos da rede de pluviômetros da cidade do Rio de Janeiro, tal como realizado pelo Alerta Rio. Porém, a previsão de ocorrência ou não de movimentos de massa, foi feita a partir do desenvolvimento de modelos de classificação binária de eventos de precipitação, ou seja, por adoção de técnicas de aprendizado de máquina.

A Tabela 18 resume as diretrizes básicas, que nortearam o presente estudo. Adicionalmente à estas diretrizes, tem-se as seguintes pontuações:

- I. Quanto à heterogeneidade das zonas de alerta: Calvellido *et al.* (2015) não apresentaram, explicitamente, indicadores que caracterizariam zona de alerta homogênea (item 1.2.4.1). Porém, compreende-se que a subdivisão das atuais zonas de alerta, em subáreas, pode resultar em regiões de características mais semelhantes e, possivelmente, menos heterogêneas. Para averiguar tal possibilidade, optou-se por realizar um pré-estudo (item 3.3) utilizando indicadores estatísticos e referências probabilísticas associadas à precipitação e a movimentos de massa;
- II. Relativamente à ocorrência de falsos-positivos: Foram adotadas métricas para verificação de desempenho de modelos (item 4).

Tabela 18. Diretrizes da Análise

| Aspecto | Descrição |
|--------------|---|
| Espacial | <ul style="list-style-type: none"> ✓ Discretização/redução das zonas de alerta com intuito de minimizar heterogeneidades e de definir a área de estudo; ✓ Vinculação da precipitação com as estações pluviométricas de cobertura da área de estudo. |
| Temporal | <ul style="list-style-type: none"> ✓ Adoção da data de ocorrência do movimento de massa como unidade de referência; ✓ Consideração de intervalos diários de 24h para composição das modulações de precipitação. |
| Metodológico | <ul style="list-style-type: none"> ✓ Contabilização de: <ul style="list-style-type: none"> a) atributos de precipitação, como acumulada e duração; b) precipitação antecedente, no que concerne ao período temporal de 4 dias (96h). ✓ Análise estatística; ✓ Estruturação e tratamento de dados para preparação do conjunto de dados de entrada; ✓ Desenvolvimento de modelos de classificação binária, por meio de treinamento, validação e teste. |

Em termos de estruturação da metodologia, na Figura 35 é apresentado o fluxo de desenvolvimento do modelo. O infográfico (Figura 35) relaciona as 5 (cinco) principais etapas utilizadas nesta pesquisa e apresenta os capítulos 3, 4 e 5 em uma sequência de ações conectadas.



Figura 35 – Fluxo de Desenvolvimento e Resultados dos Modelos

3.1 Coleta de Dados

A coleta de dados é precedida da definição da área de interesse para realização do estudo. Em sequência, são apresentados os dados de movimentos de massa originados a partir do histórico de registro da Geo-Rio.

Os dados do histórico são utilizados para estabelecimento de relação temporal, por meio das datas de ocorrência, como os eventos de precipitação que precederam ou que se desenvolveram concomitantemente com os movimentos de massa.

3.1.1 Área de Estudo

Segundo a Fundação Instituto das Águas (2015), a cidade do Rio de Janeiro é dividida em 3 (três) macrorregiões de drenagem (Figura 36). A macrorregião da Baía da Guanabara possui 10 (dez) bacias. Pela semelhança com a divisão das zonas de alerta (Figura 11), entende-se que o mapeamento da macrodrenagem atuou como referência para a definição das zonas de Alerta Guanabara, Jacarepaguá, Sepetiba e Zona Sul.

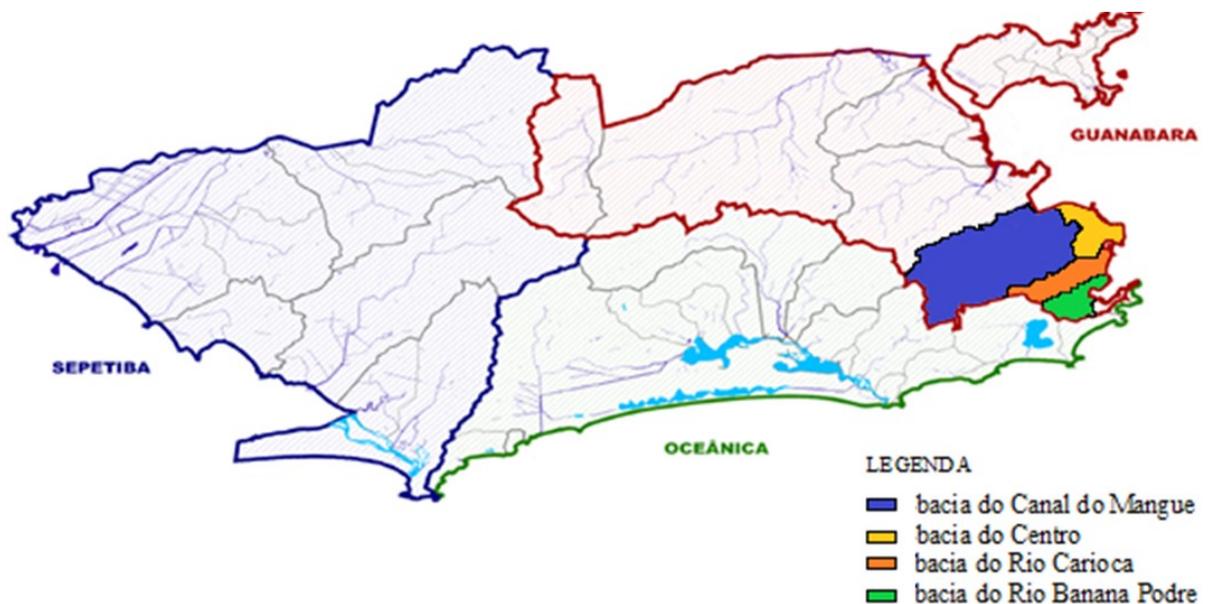


Figura 36 – Macrorregiões de Drenagem da Cidade do Rio de Janeiro, Drenagem e Manejo de Águas Pluviais Urbanas (Fundação Instituto das Águas, 2015)

Adicionalmente, na Figura 37 é apresentado o mapa de susceptibilidade a movimentos de massa da cidade do Rio de Janeiro. As áreas em vermelho e amarelo representam os níveis de susceptibilidade mais elevados e estão concentradas nas encostas do Maciço da Tijuca, do Maciço da Pedra Branca e do Maciço de Gericinó.

Considerando-se a necessidade de eleger uma região e, também, que tal região oferte quantidade representativa de dados para desenvolvimento da pesquisa, adotou-se o compilado de movimentos de massa ocorridos no Maciço da Tijuca no período de 2009 a 2015.



Figura 37 – Mapa de suscetibilidade a movimentos de massa da cidade do Rio de Janeiro - Áreas em amarelo são de média suscetibilidade e áreas em vermelho são de alta suscetibilidade - Geo-Rio (2015)

Estes registros de movimentos de massa foram fornecidos pela Diretoria de Fiscalização e Licenciamento (DFL) da Fundação Geo-Rio e demandou manipulação de um extenso banco de dados por parte de Albuquerque (2019) para desenvolvimento de sua pesquisa. Entende-se que a compilação realizada por Albuquerque (2019) se limitou ao ano de 2009 em função da dificuldade de acesso a registros anteriores, tanto devido à natureza física, à forma de arquivamento e à antiguidade dos documentos, quanto à ausência de informações baseadas no sistema SIG, o qual se faz primordial para desenvolvimento das análises.

Além disso, com intuito de ampliar o banco de dados de movimentos de massa, em 2023 foi realizada uma consulta informal à Geo-Rio, para verificar seu posicionamento quanto ao fornecimento de dados de movimentos de massa referentes ao período de 2016 a 2023. Entretanto, em função da Lei Geral de Proteção de Dados -LGPD (Lei 13.709/2018), não foi possível ampliar o intervalo de dados, utilizando-se então os dados compilados por Albuquerque (2019).

Albuquerque (2019) relacionou 837 movimentos de massa registrados, dos quais 354 (trezentos e cinquenta e quatro) continham data de ocorrência. A informação de data é fundamental para relacionar movimento de massa com a pluviometria. Para avaliar as possíveis regiões com maior concentração de movimentos de massa, os 354 (trezentos e cinquenta e quatro) pares de coordenadas foram posicionadas geograficamente através do Programa QGIS, como mostra a Figura 38.

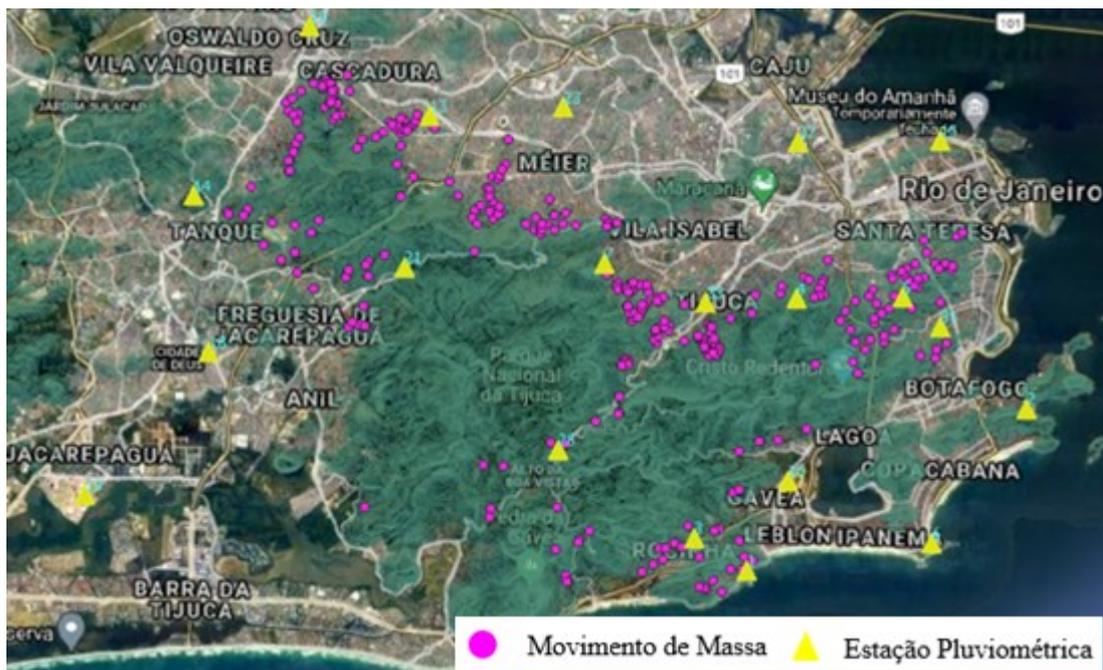


Figura 38 – Movimento de Massa no Maciço da Tijuca

3.1.2 Movimentos de Massa

A distribuição geográfica dos movimentos de massa com data, relacionados por Albuquerque (2019), para o período de 2009 a 2015, permitiu a observação da concentração de 139 (cento e trinta e nove) movimentos (Figura 39) na macrorregião de drenagem da Guanabara, mais especificamente na região composta pela união das bacias do Canal do Mangue, do Centro, do Rio Carioca e do Rio Banana Podre (Figura 36).

A Figura 39 apresenta a localização espacial dos 139 eventos, em conjunto com a identificação numérica (#n) das estações pluviométricas de entorno. Desta forma, uma vez que aproximadamente 40% dos movimentos de massa se distribuem nesta região da Guanabara e que sua adoção converge com o objetivo de discretização/redução da zona de alerta (Tabela 18), optou-se pela escolha desta região como área de estudo.

A fim de estabelecer uma relação espacial entre os movimentos de massa e a localização das estações pluviométricas foi utilizada uma ferramenta, disponível no programa QGIS, para obtenção dos Polígonos de Thiessen (Figura 40). Esse método possui ampla utilização no meio científico e profissional, podendo-se citar os trabalhos de Abraham *et al.* (2019), Park *et al.* (2019) e Zhao *et al.* (2019).

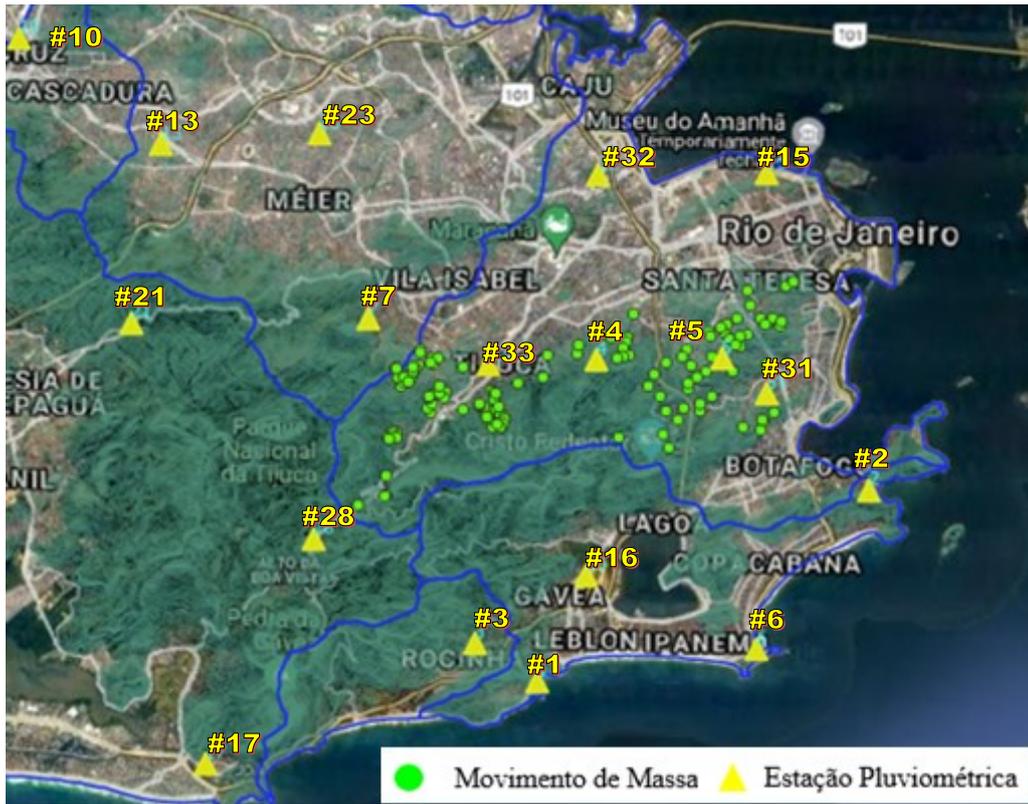


Figura 39 – Movimento de Massa - Área de estudo



Figura 40 – Polígonos de Thiessen e Movimento de Massa

Ressalta-se, contudo, que a geração de polígonos não considera elevação terreno. Portanto, deve-se atentar que, dentre as estações relacionadas há aquelas que realizam a cobertura dos pontos mais elevados da região considerada.

A Figura 40 mostra o mapa gerado com os polígonos de Thiessen. Observa-se que os movimentos de massa, referentes à área de estudo, relacionam-se com as estações pluviométricas Tijuca (#4), Santa Teresa (#5), Grajaú (#7), Alto da Boa Vista (#28) e Laranjeiras (#31).

As estações Grajaú (#7) e Alto da Boa Vista (#28) não estão inseridas na região adotada. Porém, quando da geração dos polígonos de Thiessen, foi possível perceber que suas áreas de cobertura avançam sobre a área de estudo.

A estação pluviométrica Tijuca-Muda (#33) não foi considerada, pois sua ativação ocorreu em fevereiro de 2011, enquanto o intervalo de estudo se inicia em 2009. As estações pluviométricas São Cristóvão(#32), Saúde(#15) e Urca (#2) não foram adotadas por não ser contabilizado movimento de massa relacionado a estas áreas de cobertura (Figura 39).

3.2 Pré-Processamento de Dados

Os movimentos de massa deflagrados, na cidade do Rio de Janeiro, são registrados em boletins de ocorrências gerados pela Fundação Geo-Rio. Relativamente a tais boletins, há algumas ressalvas quanto à precisão dos registros, à descrição e à análise do movimento (volume mobilizado, tipologia do movimento, localização etc.). Nem todos os boletins possuem hora e data dos movimentos de massa, dados esses fundamentais para o emprego dos sistemas de alerta correlacionados a eventos de precipitação.

É possível observar (item 3.1) que apenas 42% dos boletins de ocorrência do banco de dados analisado por Albuquerque (2019) contêm registro da data. Logo, verifica-se que o registro do horário da ocorrência é informação rara. Sendo assim, em função das dificuldades em se obter registro do horário dos movimentos de massa, a análise desenvolvida nesta pesquisa é baseada na acumulada diária (mm) relacionada às datas das suas deflagrações.

Os eventos de precipitação são originados do sistema de estações pluviométricas da Prefeitura do Rio de Janeiro. Na página do Alerta Rio, estão disponíveis para download os registros de precipitação das estações pluviométricas que compõem a rede.

Para cada estação pluviométrica, em intervalos de 15 minutos, é realizado registro da altura (mm) de precipitação captada. Estes registros são apresentados em arquivo digitais com extensão .txt. Para situações de falha de registro da precipitação diária, utilizou-se nesta ordem de preferência: o “Método de Ponderação Regional”, em que são utilizadas pelo menos 3 (três) estações pluviométricas vizinhas, com características climatológicas similares para realização do preenchimento das falhas de registro (Tucci, 2009; Jardim e Silva; 2017); ou o descarte do dia em que houve falha de precipitação (Jardim e Silva; 2017).

Em face do grande volume de dados de precipitação coletados e considerando a disponibilidade de ferramentas computacionais, adotou-se o software MATLAB para pré-processamento destas informações. No MATLAB foram criadas rotinas para geração da acumulada diária (mm) e sua duração (h), para cada uma das estações relacionadas aos movimentos de massa localizados na área de estudo. Estas rotinas consistem: na conversão do arquivo .txt em tabela; no somatório, para um mesmo dia (data), das acumuladas e das durações, geradas a cada intervalo de 15 minutos; na geração de uma tabela com as acumuladas e durações diárias, ou seja, de uma mesma data.

Neste contexto, o pré-processamento de dados de movimentos de massa foi realizado em duas etapas. Na primeira etapa, foram aplicados critérios referente às localizações (quadras, ruas, encostas) dos movimentos e às datas de suas deflagrações. Na segunda etapa, foram aplicados critérios relacionados à precipitação, para obtenção de parâmetro sobre a manutenção ou não manutenção de determinados movimentos de massa no grupo de dados de entrada. Além disto, em cada etapa, a área de estudo foi considerada de duas formas distintas:

- a) Representada por 5 (cinco) estações pluviométricas (Figura 40);
- b) Representada por uma estação pluviométrica virtual, denominada “Estação Média”.

A Estação Média configura uma simplificação, na qual a área de estudo é representada por uma estação única. Tal estação é originada a partir do valor médio das acumuladas diárias registradas em cada uma das 5 (cinco) estações pluviométricas (item 3.1), ou seja, para cada data/dia foi calculada a média das acumuladas diárias e das durações captadas nas estações pluviométricas Tijuca (#4), Santa Teresa (#5), Grajaú (#7), Alto da Boa Vista (#28) e Laranjeiras (#31).

A seguir, para as formas (a) e (b) supracitadas, são aplicados os critérios da etapa 1 e da etapa 2. Também, no item 3.3, são desenvolvidas análises estatísticas para fins de comparação entre tais formas.

3.2.1 Estações Pluviométricas

3.2.1.1. Etapa 1 – Critérios de Localização e de Data de Ocorrência

Na primeira etapa do pré-processamento dos dados de movimentos de massa, foram excluídos os movimentos cuja localização registrada pertence à região urbanizada (quadras, ruas etc.) em vez de encostas. Também, foram agrupados movimentos ocorridos em uma mesma data, visto que a unidade de referência é a data de ocorrência do movimento.

No item 3.1 foram identificados 139 eventos de movimento de massa (Figura 39), no período de 2009 a 2015, abrangendo as estações pluviométricas Tijuca (#4), Santa Teresa (#5), Grajaú (#7), Alto da Boa Vista (#28) e Laranjeiras (#31).

A metodologia desenvolvida neste trabalho utiliza a data de ocorrência dos movimentos de massa como unidade de referência. Busca-se estruturar os dados para utilização de modelo de aprendizado de máquina para previsão de ocorrência (1) ou de não ocorrência (0). Neste contexto, foi adotado um modelo binário, que considera o fato de ter havido ocorrência de movimento em determinada data, mas que não contabiliza a quantidade de movimentos de massa deflagrados em um mesmo dia.

A título de exemplo, caso no dia 01/01/2009, na região da estação pluviométrica Tijuca, tenham sido registrados 10 (dez) movimentos de massa, não será contabilizada a quantidade de movimentos, mas sim o fato de que nesta data houve movimento de massa. Desta forma, dos 139 eventos de movimentos de massa registrados (item 3.1), contabiliza-se um total 54 eventos distribuídos em datas distintas para cada uma das estações, conforme colunas (a) e (b) da Tabela 19.

Tabela 19 – Critérios - Movimentos de Massa – Estação Pluviométrica – Etapa 1

| Estações | (a) Total de registros de movimentos de massa | (b) Datas com registros de movimentos de massa |
|-------------------|--|--|
| Alto da Boa Vista | 4 | 2 |
| Grajaú | 40 | 11 |
| Laranjeiras | 6 | 3 |
| Santa Teresa | 41 | 15 |
| Tijuca | 48 | 23 |
| Total | 139 | 54 |

3.2.1.2. Etapa 2 - Critérios Pluviométricos

Na segunda etapa do pré-processamento dos dados de movimentos de massa, foi observado que uma parcela dos eventos apresentava dados de precipitação relacionadas a valores baixos de acumuladas ou valores díspares das acumuladas registradas dos demais eventos que compunham o conjunto de dados de entrada.

Atribui-se esta inconsistência de valores a possíveis equívocos de preenchimento do campo “data” dos boletins de ocorrência. Nestes casos os boletins são classificados com média ou baixa confiabilidade, de forma que, dentre as informações coletadas, a data indicada pode não representar a data real da ocorrência dos movimentos de massa.

Com a finalidade de verificar a pertinência em se manter os eventos cujas acumuladas apresentam valores díspares, foi realizada análise comparativa entre as correlações de precipitação acumulada de 24h e 96h apresentadas nos relatórios de movimentos de massa da Geo-Rio (2010, 2011), e também em relação ao fator distribuição de precipitação apresentado por Chaves (2016).

Os relatórios da Geo-Rio indicaram dispersão dos eventos de confiabilidade 1 nos gráficos referentes à análise da correlação mm/24h x mm/96h. A dispersão conduz ao entendimento de haver relação entre deflagração de movimentos de massa e acumuladas diárias a partir de 30mm.

Ainda, os estudos realizados por Chaves (2016) indicam haver representativa correlação entre a deflagração de movimentos de massa para fator de distribuição acima de 40%, ou seja, para eventos cuja precipitação acumulada das 96h é maior ou igual a 40% da expectativa de precipitação mensal (Figura 41).

Desta forma, estabeleceu-se que para a manutenção de evento de movimento de massa no conjunto de dados de entrada se faz necessário o atendimento dos seguintes critérios:

- I. Acumulada diária igual ou maior que 30mm em qualquer um dos 4 (quatro) intervalos e;
- II. Somatório das acumuladas diárias dos 4 (quatro) intervalos seja igual ou maior que 40% da estimativa de precipitação mensal.

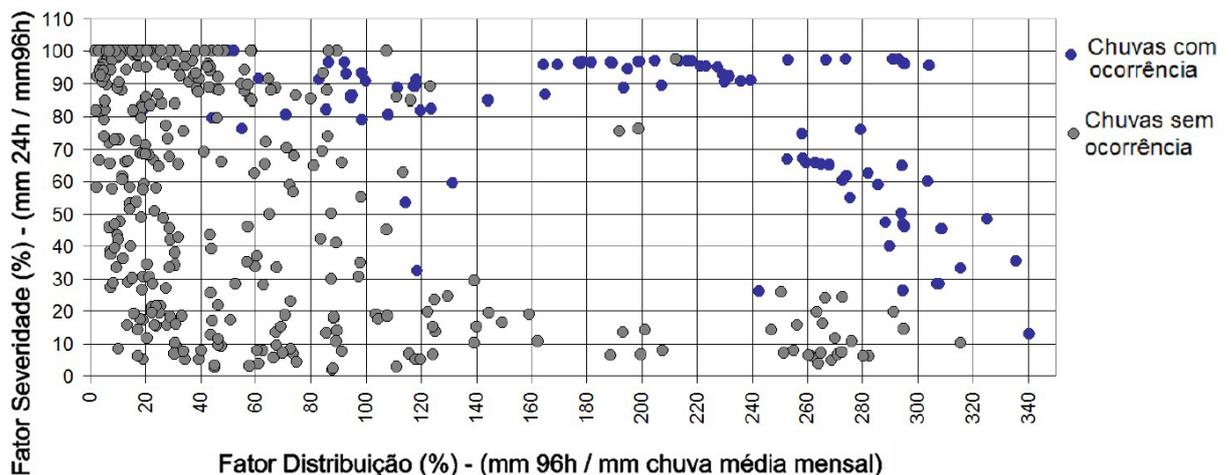


Figura 41 – Dispersão Fatores Severidade e Distribuição (Chaves,2016).

Sendo assim, além da estruturação dos dados em função da data (item 3.2.1.1), foi necessário averiguar a pertinência da manutenção de cada um dos eventos de movimento a partir da aplicação dos critérios I e II citados anteriormente. Neste contexto, das 54 datas distintas (Tabela 19) em que ocorreram movimento de massa, após a aplicação dos critérios I e II, concluiu-se pela manutenção de 33 eventos de movimento de massa, tal como apresentado na coluna (c) da Tabela 20.

Tabela 20 – Critérios - Movimentos de Massa – Estação Pluviométrica – Etapa 2

| Estações | (a) Total de registros de movimentos de massa | (b) Datas com registros de movimentos de massa | (c) Movimentos de massa considerados |
|-------------------|--|--|--|
| Alto da Boa Vista | 4 | 2 | 2 |
| Grajaú | 40 | 11 | 6 |
| Laranjeiras | 6 | 3 | 2 |
| Santa Teresa | 41 | 15 | 9 |
| Tijuca | 48 | 23 | 14 |
| Total | 139 | 54 | 33 |

Logo, dos 139 movimentos de massa registrados, foram adotados 33 (trinta e três) movimentos no período de 2009 a 2015. A Figura 42 mostra a distribuição espacial, por polígono de Thiessen, dos movimentos considerados e a Tabela 21 apresenta a compilação deste movimentos, por estação pluviométrica, resultante da aplicação dos critérios das etapas 1 e 2.



Figura 42 – Movimentos de Massa – Estações Pluviométricas

Tabela 21 – Estações Pluviométricas – Movimentos de Massa 2009 a 2015

| Evento | Estação | Data | Acumulada (mm/24h) | Duração [h] |
|--------|-------------------|------------|-----------------------|----------------|
| 1 | Santa Teresa | 04/12/2009 | 63,6 | 15,25 |
| 2 | Santa Teresa | 10/12/2009 | 42,2 | 10 |
| 3 | Grajaú | 10/12/2009 | 33 | 8,25 |
| 4 | Santa Teresa | 11/12/2009 | 1,2 | 1 |
| 5 | Tijuca | 30/12/2009 | 48,4 | 9,75 |
| 6 | Santa Teresa | 30/12/2009 | 32,2 | 9,75 |
| 7 | Tijuca | 15/01/2010 | 95,2 | 10,25 |
| 8 | Tijuca | 16/01/2010 | 0,8 | 0,75 |
| 9 | Santa Teresa | 06/03/2010 | 82,6 | 5 |
| 10 | Tijuca | 06/03/2010 | 104,4 | 4,5 |
| 11 | Grajaú | 07/03/2010 | 0,2 | 0,5 |
| 12 | Tijuca | 17/03/2010 | 44,4 | 8,75 |
| 13 | Tijuca | 05/04/2010 | 115,8 | 9 |
| 14 | Grajaú | 05/04/2010 | 114,4 | 9,5 |
| 15 | Santa Teresa | 05/04/2010 | 96 | 8,75 |
| 16 | Laranjeiras | 05/04/2010 | 82 | 9,5 |
| 17 | Tijuca | 06/04/2010 | 213,2 | 21,75 |
| 18 | Santa Teresa | 06/04/2010 | 186,4 | 21,75 |
| 19 | Grajaú | 06/04/2010 | 150 | 19,25 |
| 20 | Alto da Boa Vista | 06/04/2010 | 193,1 | 21,5 |
| 21 | Laranjeiras | 06/04/2010 | 179,6 | 21 |
| 22 | Alto da Boa Vista | 09/04/2010 | 12,6 | 3,5 |
| 23 | Santa Teresa | 25/04/2011 | 67,6 | 4,75 |
| 24 | Tijuca | 25/04/2011 | 170 | 4,5 |
| 25 | Tijuca | 26/04/2011 | 67,2 | 9,25 |
| 26 | Tijuca | 15/01/2013 | 58,8 | 3,5 |
| 27 | Santa Teresa | 17/01/2013 | 33,6 | 3,25 |
| 28 | Tijuca | 22/01/2013 | 30,2 | 4,25 |
| 29 | Grajaú | 23/01/2013 | 0 | 0 |
| 30 | Tijuca | 18/03/2013 | 68,6 | 11,5 |
| 31 | Grajaú | 18/03/2013 | 37,6 | 11,75 |
| 32 | Tijuca | 06/12/2013 | 3 | 1,25 |
| 33 | Tijuca | 11/12/2013 | 112,6 | 15,25 |

3.2.2 Estação Média

3.2.2.1. Etapa 1 – Critérios de Localização e de Data de Ocorrência

De forma similar ao efetuado no item 3.2.1.1, na primeira etapa do pré-processamento dos dados de movimentos de massa, foram excluídos os movimentos cuja localização registrada pertence à região urbanizada (quadras, ruas etc.) em vez de encostas. Também, foram agrupados movimentos ocorridos em uma mesma data, visto que a unidade de referência é a data de ocorrência do movimento.

Conforme indicado no item 3.2, a utilização da Estação Média representa uma simplificação, uma vez que unifica a área de estudo, e implica admitir que, para a área de estudo, adota-se a média das precipitações diárias das 5 (cinco) estações (item 3.1) como referência para desenvolvimento dos estudos.

Originalmente, foram identificados 139 eventos de movimento de massa (item 3.1), os quais, adotando-se a Estação Média, ocorreram em 42 datas distintas, conforme Tabela 22. Em termos de conceito, as análises realizadas consideram a ocorrência de movimento de massa relacionadas ao evento de precipitação captado pela(s) estação(ões) de referência. Neste caso específico, a referência é a Estação Média.

Para cada data com precipitação é admitido que houve ou que não houve movimento de massa, resultando-se na consideração da ocorrência de movimento de massa por data e por estação, embora seja comum que diversos movimentos de massa ocorram em sequência, em uma mesma data, quando da ocasião de eventos extremos de precipitação.

Logo, a redução da quantidade de movimentos de massa de 139 para 42 (quarenta e dois) eventos resulta da adoção de apenas uma estação de referência, a Estação Média. Reforça-se que os dados foram estruturados para utilização de modelo de aprendizado de máquina para previsão de ocorrência (1) ou de não ocorrência (0), ou seja foi adotado um modelo binário, que não considerará a quantidade de movimentos de massa deflagrados em uma mesma data, mas sim o fato de ter havido ocorrência de movimento.

Tabela 22 – Critérios - Movimentos de Massa – Estação Média – Etapa 1

| Estações | (a) Total de registros de movimentos de massa | (b) Datas com registros de movimentos de massa |
|----------|--|--|
| Média | 139 | 42 |

3.2.2.2. Etapa 2 - Critérios Pluviométricos

Na segunda etapa do pré-processamento dos dados de movimentos de massa, foi observado que uma parcela dos eventos apresentava dados de precipitação relacionadas a valores baixos de acumuladas, valores díspares das acumuladas registradas nos demais eventos que compunham o conjunto de dados de entrada.

Sendo assim, de forma similar ao efetuado no item 3.2.1.2, além da estruturação dos dados em função da data (item 3.2.2.1), foi necessário averiguar a pertinência da manutenção de cada um dos eventos de movimento a partir da aplicação dos critérios I e II apresentados no item 3.2.1.2. Neste contexto, das 42 datas distintas (Tabela 22) em que ocorreram de movimento de massa, após a aplicação dos critérios I e II, decidiu-se pela manutenção de 21 eventos de movimento de massa, tal como apresentado na coluna (c) da Tabela 23.

Tabela 23 – Critérios - Movimentos de Massa – Estação Média – Etapa 2

| Estações | (a) Total de registros de movimentos de massa | (b) Datas com registros de movimentos de massa | (c) Movimentos de massa considerados |
|---------------|--|--|--|
| Estação Média | 139 | 42 | 21 |

Logo, dos 139 movimentos de massa registrados, foram considerados 21 (vinte e um) movimentos pertencentes a Estação Média no período de 2009 a 2015. A Figura 43 mostra a distribuição espacial, por polígono de Thiessen, dos movimentos incorporados e a Tabela 24 apresenta a compilação deste movimentos, por estação pluviométrica, resultante da aplicação dos critérios das etapas 1 e 2.

Considerando-se a série histórica de precipitação e estabelecendo-se a relação espacial com a área de estudo por meio dos polígonos de Thiessen (ou diagrama de Voronoi), foram feitas análises estatísticas (item 3.3) anteriormente ao desenvolvimento dos modelos de aprendizado de máquina.



Figura 43 – Movimento de Massa - Estação Média

Tabela 24 – Estação Média – Movimentos de Massa 2009 a 2015

| Evento | Data | Acumulada Diária Média (mm) | Duração (h) | Evento | Data | Acumulada Diária Média (mm) | Duração (h) |
|--------|------------|-----------------------------|-------------|--------|------------|-----------------------------|-------------|
| 1 | 04/12/2009 | 66 | 15 | 12 | 09/04/2010 | 15 | 4 |
| 2 | 10/12/2009 | 44 | 10 | 13 | 25/04/2011 | 103 | 4 |
| 3 | 11/12/2009 | 1 | 1 | 14 | 26/04/2011 | 60 | 8 |
| 4 | 30/12/2009 | 53 | 10 | 15 | 15/01/2013 | 47 | 3 |
| 5 | 15/01/2010 | 76 | 10 | 16 | 17/01/2013 | 31 | 4 |
| 6 | 16/01/2010 | 1 | 1 | 17 | 22/01/2013 | 46 | 6 |
| 7 | 06/03/2010 | 90 | 5 | 18 | 23/01/2013 | 0 | 0 |
| 8 | 07/03/2010 | 0 | 0 | 19 | 18/03/2013 | 36 | 9 |
| 9 | 17/03/2010 | 39 | 9 | 20 | 06/12/2013 | 3 | 1 |
| 10 | 05/04/2010 | 102 | 9 | 21 | 11/12/2013 | 106 | 15 |
| 11 | 06/04/2010 | 182 | 21 | | | | |

3.3 Análises Estatísticas Preliminares

Apresentam-se a seguir análises realizadas para captar características dos eventos de precipitação diária relacionados à deflagração de movimentos de massa e dos eventos de precipitação diária não relacionados a tais movimentos.

Os boletins de ocorrências de movimentos de massa gerados pela Fundação Geo-Rio contêm campos disponíveis para registro de uma série de dados, dentre eles: a data e hora de deflagração (item 1.2.4). Entretanto, conforme indicado no item 3.2, a obtenção de dados de data e horário representam um desafio. Logo, optou-se por desconsiderar a hora de deflagração do movimento de massa, adotando-se exclusivamente a data de sua ocorrência. Com isso, todas as análises deste trabalho associaram a precipitação acumulada diária (mm) aos movimentos de massa ocorridos naquela data.

3.3.1 Estatística Descritiva – Dados Pluviométricos

O tratamento dos dados de precipitação resultou na obtenção dos atributos/fatores de acumuladas diárias (mm) e duração (h) para as 5 (cinco) estações pluviométricas (Figura 40): Tijuca (#4), Santa Teresa (#5), Grajaú (#7), Alto da Boa Vista (#28) e Laranjeiras (#31).

Os conjuntos de dados de acumuladas diárias (mm) e de duração (h) permite a realização de análises estatísticas descritivas dos eventos de precipitação diária com e sem ocorrência de movimentos de massa da área de estudo (Figura 40), no período de 2009 a 2015. Para fins de comparação, foram realizadas análises descritivas tomando-se individualmente os registros das 5 (cinco) estações pluviométricas em contraposição ao uso dos valores médios da Estação Média.

Desta forma, foram constituídos 4 agrupamentos distintos:

- Enfoque 1: compreende os eventos de precipitação diária de cada uma das 5 (cinco) estações tomadas individualmente;
- Enfoque 2: considera a média dos eventos de precipitação diária;
- Enfoque 3: compreende os eventos de precipitação diária associados à localização de 33 movimentos de massa (item 3.2.1);
- Enfoque 4: considera a média dos eventos de precipitação diária nas datas de deflagração de 21 movimentos de massa (item 3.2.2).

3.3.1.1. Enfoque 1: Precipitação Diária - Estações Pluviométricas

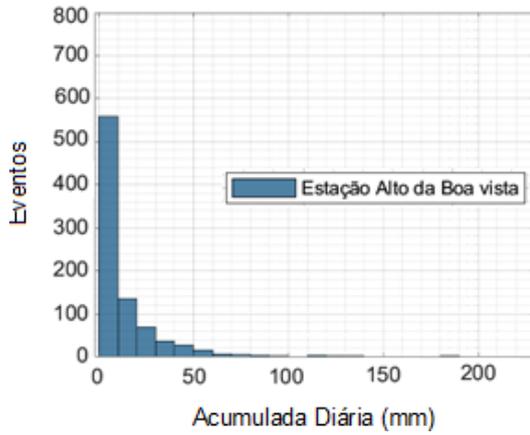
Para cada uma das 5 (cinco) estações pluviométricas (item 3.1) foram desenvolvidas representações gráficas (Figura 44 e Figura 45), tais como distribuição de frequência e dispersão para o período de 2009 a 2015, estas representações conduzem às seguintes observações:

- I. As dispersões dos eventos de precipitação (Figura 45) sinaliza tendência de aumento de acumuladas diárias com o aumento da duração dos eventos;
- II. As maiores acumuladas diárias (mm) pertencem às estações Tijuca, com 213,2 mm, e Alto da Boa Vista, com 193mm. Acumuladas diárias maiores do que 150mm possuem duração maiores do que 15h, com exceção de um evento na estação Tijuca;
- III. As estações Alto da Boa Vista e Tijuca possuem a maior quantidade de eventos acima de 100mm. Todas as estações apresentam a maioria dos eventos (95%) com acumuladas inferiores a 50mm (Tabela 25). As diferenças de pluviometria das estações Alto da Boa Vista e Tijuca, em relação às demais estações, podem estar vinculadas as suas cotas de localização. As estações Tijuca e Alto da Boa Vista estão posicionadas a 340m e 355m, respectivamente. As estações Santa Teresa, Grajaú e Laranjeiras estão situadas às cotas 170m, 80m e 60m, nesta ordem;
- IV. A maioria dos eventos (Alto: 75%; Grajaú: 82%; Laranjeiras: 87%; Santa Teresa: 93% ; Tijuca: 83%) se concentra na região de acumulada diária menor do que 50mm e de duração menor do que 10h;

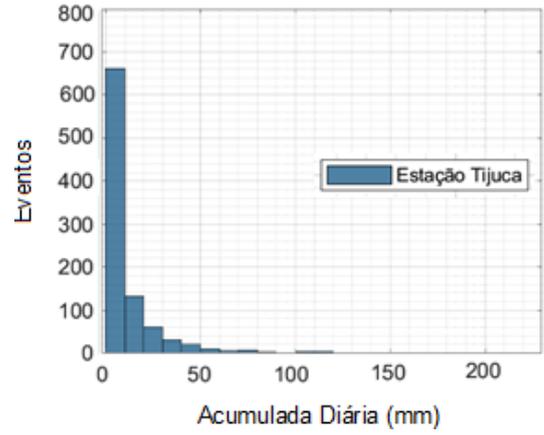
Além disso, na Tabela 25 é apresentada a proporção de eventos para determinadas classes de acumuladas diárias.

Tabela 25 – Acumuladas Diárias (24h) – Estações - 2009 a 2015

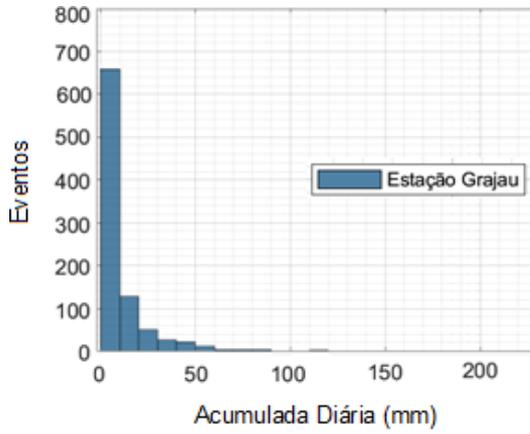
| Estações | Proporção de Eventos (%) | | | | Total de Eventos |
|-------------------|--------------------------|---------------|----------------|------------|------------------|
| | < 50mm | 50 a 100 (mm) | 100 a 150 (mm) | > 150 (mm) | |
| Alto da Boa Vista | 95 | 3,8 | 0,9 | 0,3 | 873 |
| Grajaú | 97,1 | 2,5 | 0,4 | - | 910 |
| Laranjeiras | 96,7 | 3,2 | - | 0,1 | 910 |
| Santa Teresa | 97,2 | 2,6 | 0,1 | 0,1 | 927 |
| Tijuca | 96,6 | 2,6 | 0,6 | 0,2 | 936 |



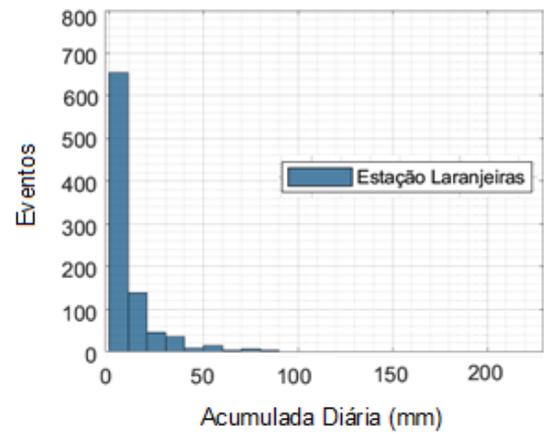
(a) Alto da Boa Vista



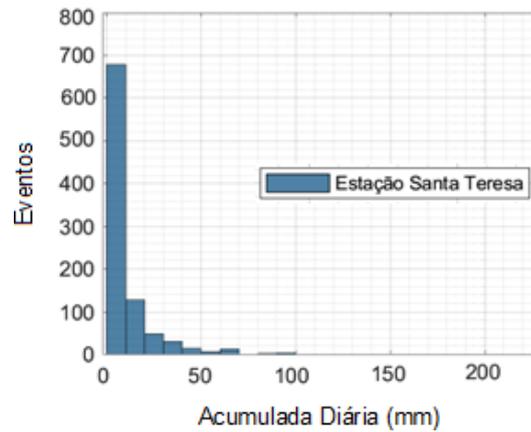
(b) Tijuca



(c) Grajaú

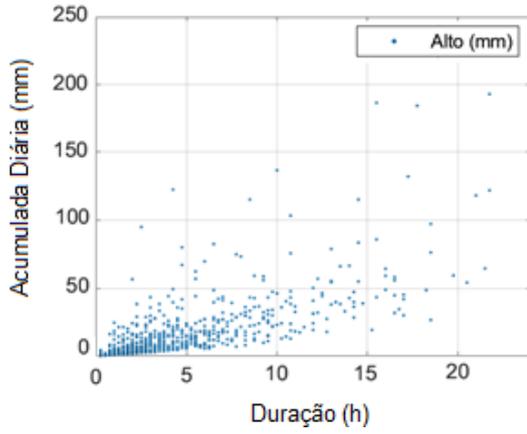


(d) Laranjeiras

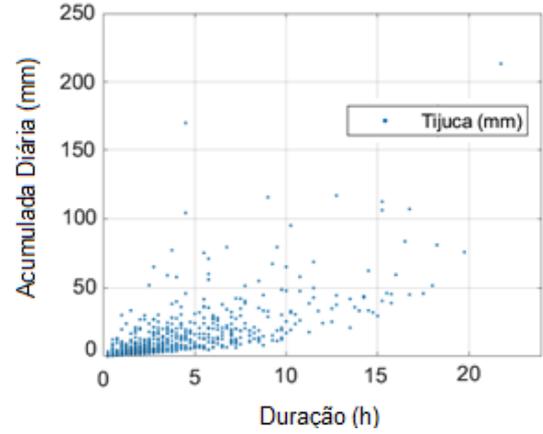


(e) Santa Teresa

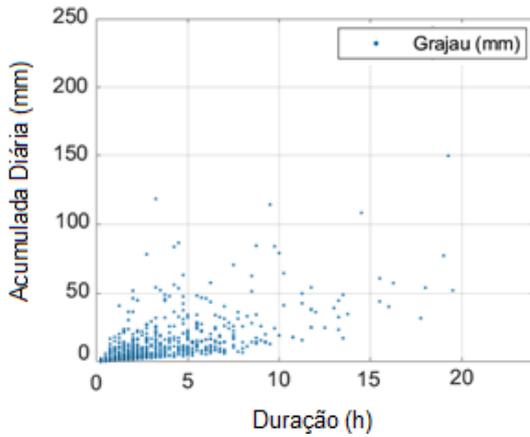
Figura 44 – Histogramas - Acumulada Diária - Estações



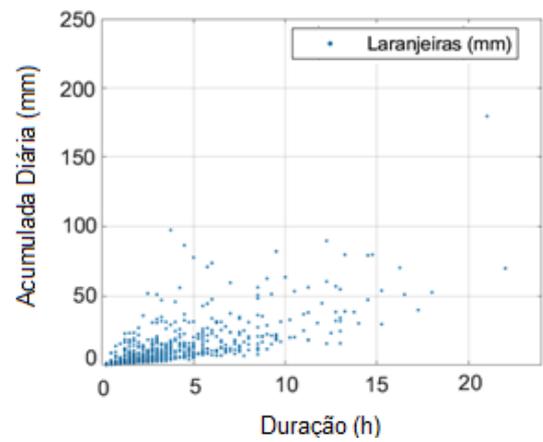
(a) Alto da Boa Vista



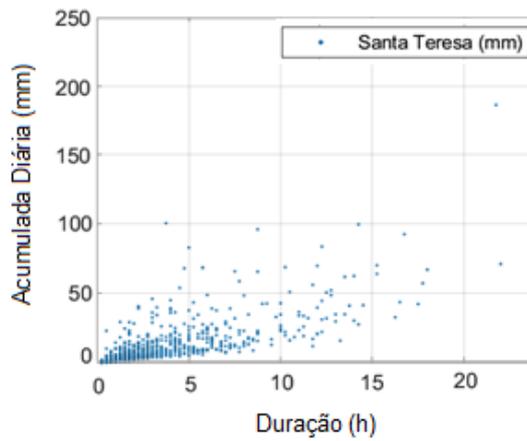
(b) Tijuca



(c) Grajaú



(d) Laranjeiras



(e) Santa Teresa

Figura 45 – Dispersões - Acumulada Diária e Duração - Estações

Além das representações gráficas, os dados de acumuladas diárias (mm) permitem o cálculo de medidas de tendência central, tais como média e mediana, e também de medida de dispersão, tal como desvio padrão. Na Tabela 26 são apresentadas estas medidas para cada conjunto de dados considerados.

Tabela 26 – Medidas de Tendência Central e de Variação – Estações - Acumulada Diária

| Estações | Média (mm) | Mediana (mm) | Desvio (mm) |
|-------------------|------------|--------------|-------------|
| Alto da Boa Vista | 13,3 | 5,4 | 21,6 |
| Grajaú | 9,6 | 3,8 | 15,4 |
| Laranjeiras | 9,4 | 3,8 | 14,9 |
| Santa Teresa | 9,4 | 3,8 | 15,2 |
| Tijuca | 10,6 | 4,4 | 18,0 |

Os valores das médias diárias das estações Grajaú, Laranjeiras e Santa Teresa são próximos, indicando característica equivalente em relação à magnitude dos dados, uma vez que o cálculo da média considera todos os elementos do conjunto de dados. As maiores médias pertencem às estações Alto da Boa Vista e Tijuca, entendendo-se que a elevação de suas médias, em relação às médias das demais estações, deve-se à existência de eventos de precipitação diária de maiores magnitudes/duração.

Os valores dos desvios padrão se comportam de maneira análoga à média, próximos para as estações Grajaú, Laranjeiras e Santa Teresa. A diferença dos valores dos desvios padrão das estações Alto da Boa Vista e Tijuca em relação às demais estações reflete a existência de eventos com maiores magnitudes, tal como se pode observar nos gráficos de dispersão.

Adicionalmente, um aspecto importante, em relação ao gráfico de distribuições de frequências, é a assimetria, a qual pode ser observada para cada uma das 5 (cinco) estações. O afastamento entre os valores de mediana e de média caracteriza a forma da distribuição de frequência, que neste caso é assimétrica à direita, com a média maior do que a mediana. Os valores de desvio refletem a dispersão da distribuição em relação à média e sinalizam a existência de assimetria representativa.

Em função da quantidade de eventos com acumuladas abaixo de 50mm, o formato da distribuição de frequência não permite destaque dos eventos de acumuladas acima de 50mm. Uma forma de evidenciar estes eventos, que se descolam e potencializam a assimetria à direita, é o diagrama de caixa.

Para fins de resgate do significado dos elementos que compõem um diagrama de caixa, na Figura 46 tem-se uma representação genérica de modelo. Neste diagrama, a caixa contém 50% dos dados e a representação da mediana (2º. Quartil). Abaixo do 1º. quartil há demais 25% dos dados e os 25% restantes estão acima do 3º. quartil. O diagrama também apresenta 2 limites (inferior e superior), denominados adjacentes, que limitam uma faixa de “regularidade”. Dados excedentes a esses limites são denominados de pontos atípicos/discrepantes (*outliers*), pois se afastam dos demais valores da série de dados analisada.

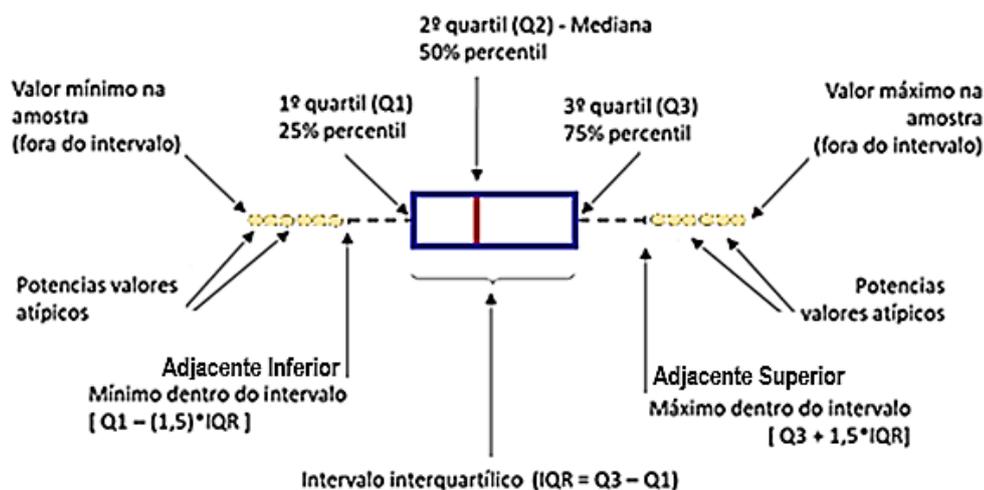


Figura 46 – Diagrama de Caixa – Modelo Informativo

Na Figura 47 são apresentados os diagramas de caixa das 5 (cinco) estações pluviométricas. A caixa comporta os 50% valores centrais, a linha interna representa a mediana e os pontos externos, atípicos, correspondem aos valores discrepantes relacionados à assimetria.

Os valores das medidas de posição, bem como a quantidade de valores discrepantes e o total de eventos computados para cada estação pluviométrica estão resumidos na Tabela 27. Observa-se que:

- I. As estações Grajaú, Laranjeiras e Santa Teresa apresentam alguns eventos de precipitação com acumuladas diárias acima de 100mm, mas a maioria dos eventos discrepantes possuem acumuladas inferiores a 100mm;
- II. As estações Alto da Boa Vista e Tijuca apresentam maior quantidade de eventos discrepantes acima de 100mm, também, a maior acumulada diária ocorre na estação Tijuca, com 213,2 mm;

- III. Os maiores valores de mediana 5,4mm e 4,4 mm pertencem às estações Alto da Boa Vista e Tijuca, respectivamente, destacando-se levemente dos valores das demais estações. Esta diferença pode estar relacionada ao fato de que as estações Alto da Boa Vista e Tijuca possuem mais eventos de acumuladas diárias com maiores magnitudes, quando comparadas às demais estações, implicando em deslocamento de suas medianas para a direita.

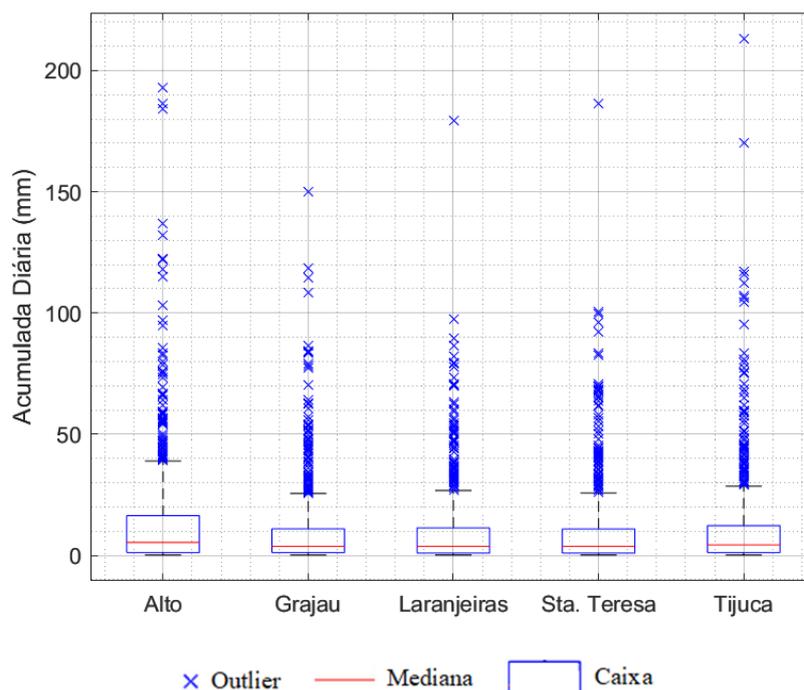


Figura 47 – Diagrama de Caixa – Estações Pluviométricas

Tabela 27 – Medidas de Posição – Acumulada Diária - Estações - 2009 a 2015

| Estações | Quartis (mm) | | | Limites (mm) | | Adjacente (mm) | Registros discrepantes s | Total de registros |
|-------------------|--------------|------------------|----------|--------------|--------|----------------|--------------------------|--------------------|
| | 1º (25%) | 2º Mediana (50%) | 3º (75%) | Mínimo | Máximo | Superior | Superior | |
| Alto da Boa Vista | 1,2 | 5,4 | 16,4 | 0,2 | 193 | 39 | 76 | 873 |
| Grajaú | 1,2 | 3,8 | 11 | 0,2 | 150 | 25,6 | 89 | 910 |
| Laranjeiras | 1 | 3,8 | 11,4 | 0,2 | 179,6 | 26,8 | 78 | 910 |
| Santa Teresa | 1 | 3,8 | 10,9 | 0,2 | 186,4 | 25,8 | 85 | 927 |
| Tijuca | 1,2 | 4,4 | 12,3 | 0,2 | 213,2 | 28,6 | 89 | 936 |

3.3.1.2. Enfoque 2: Precipitação Diária - Estação Média

A adoção da Estação Média (item 3.2), a qual contabiliza a média das precipitações diárias das 5 (cinco) estações (item 3.1), repercute no incremento de eventos e resulta no total de 1053 dias e, também, em valores médios que são menores do que algumas das acumuladas e durações que os originaram. Em outras palavras, pode-se considerar que a Estação Média é uma estação virtual, uma vez que, para representar uma unidade, ocorre o afastamento de características individuais de cada estação.

Para a Estação Média, para o período de 2009 a 2015, foram desenvolvidas representações gráficas (Figura 48 e Figura 49) de distribuição de frequência e de dispersão, estas representações conduzem aos seguintes apontamentos:

- I. As dispersões dos eventos de precipitação (Figura 49) sinaliza haver tendência de aumento de acumuladas diárias com o aumento da duração dos eventos;
- II. A comparação entre o histograma de frequência da Estação Média (Figura 48) e os histogramas das demais 5 (cinco) estações (Figura 44) indica aumento do número de eventos de 0-50mm. Entende-se que este aumento pode ser originado do abatimento das acumuladas de maiores magnitudes, que em sua maioria pertencem às estações Alto da Boa Vista e Tijuca ou, ainda, pode ser originado do fato de que nem todos os eventos ocorrem nas mesmas datas. Ademais, o abatimento é evidenciado quando se compara o gráfico de dispersão da Estação Média (Figura 49) com os gráficos de dispersão das estações Alto da Boa Vista e Tijuca (Figura 45).
- III. A maior acumulada diária computada pela Estação Média é 182,3 mm, os eventos estão mais concentrados no intervalo de 0-50mm, existindo menos eventos acima de 50mm ou de 100mm, quando comparados com as estações Alto da Boa Vista e Tijuca.
- IV. Em termos de similaridade, a Estação Média apresenta magnitudes de acumulada que a aproximam das estações Grajaú, Santa Teresa e Laranjeiras. Ademais, na Tabela 28 é apresentada a proporção de eventos para determinadas classes de acumuladas diárias da Estação Média.

Tabela 28 – Acumuladas Diárias(24h) - Estação Média - 2009 a 2015

| Estações | Proporção de Eventos (%) | | | | Total de Eventos |
|---------------|--------------------------|---------------|----------------|------------|------------------|
| | < 50mm | 50 a 100 (mm) | 100 a 150 (mm) | > 150 (mm) | |
| Estação Média | 96,8 | 2,7 | 0,3 | 0,2 | 1053 |

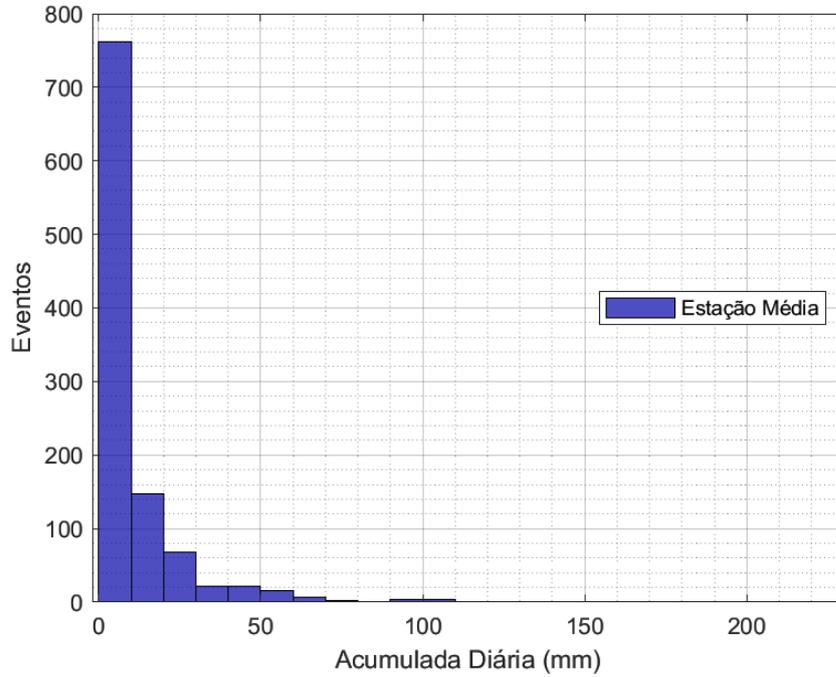


Figura 48 – Histograma - Acumulada Diária – Estação Média

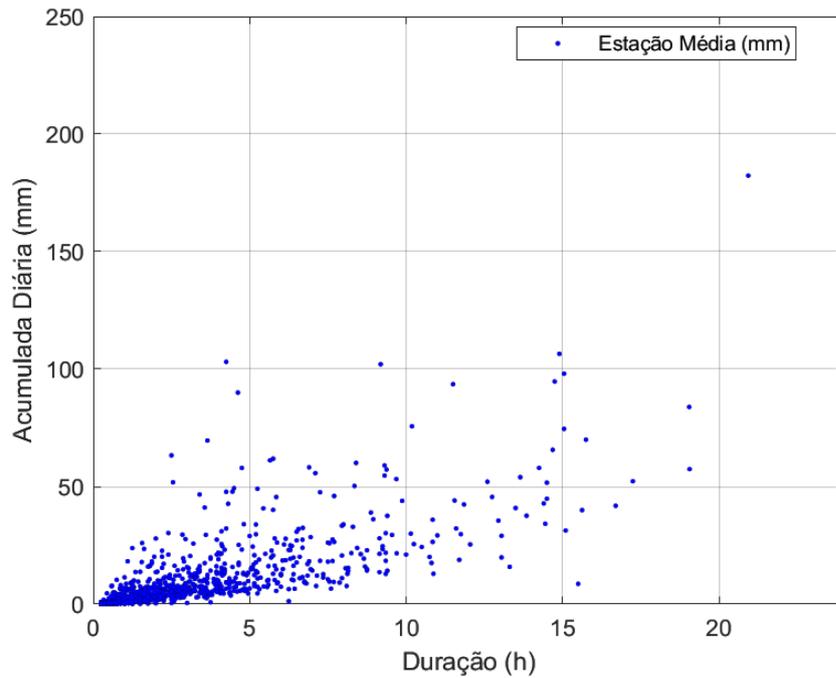


Figura 49 – Dispersão - Acumulada Diária e Duração – Estação Média

Além das representações gráficas, na Tabela 29 são apresentadas, para a Estação Média, as medidas de tendência central, tais como média e mediana, e também de medida de dispersão.

Tabela 29 – Medidas de Tendência Central e de Variação – Estação Média
Acumulada Diária Média

| Estações | Média (mm) | Mediana (mm) | Desvio (mm) |
|---------------|------------|--------------|-------------|
| Estação Média | 9,6 | 4,3 | 15,3 |

Ademais, a forma assimétrica do gráfico de distribuições de frequências é um aspecto importante. O afastamento entre os valores de mediana e de média caracteriza a assimetria à direita, com a média maior do que a mediana. Os valores de desvio refletem a dispersão da distribuição em relação à média e sinalizam a existência de assimetria representativa. A Figura 50 compara os diagramas de caixa das 5 (cinco) estações pluviométricas com a Estação Média, enquanto a quantidade de valores discrepantes, ou seja discrepantes dos demais valores da série de dados, e o total de eventos computados para a Estação Média estão resumidos na Tabela 30. Observa-se que:

- I. Na Figura 50, todos os diagramas mostram a presença de valores discrepantes, característicos de uma distribuição assimétrica. O cálculo da média resulta numa redução da faixa de variabilidade das precipitações diárias, a maior acumulada diária foi registrada na estação Tijuca (213,2 mm), enquanto a máxima média computada foi de 182,3 mm;
- II. A Estação Média registrou valores discrepantes para acumuladas acima de 26,48mm, similar ao que ocorre com as estações Tijuca, Grajaú, Laranjeiras e Santa Teresa. Entretanto, a quantidade de registros discrepantes em relação à Tabela 27 aumentou, possivelmente devido à influência dos registros das estações Tijuca e Alto.

Tabela 30 – Medidas de Posição – Acumulada Diária - Estação Média - 2009 a 2015

| Valores médios das estações pluviométricas | Quartis (em mm) | | | Valores limites (em mm) | | Adjacente (em mm) | Registros discrepantes | Total de registros |
|--|-----------------|---------------------|----------|-------------------------|-------|-------------------|------------------------|--------------------|
| | 1º (25%) | 2º (50%) Mediana | 3º (75%) | Mín. | Máx. | Superior | Superior | |
| | 1 | 4,3 | 11,3 | 0,1 | 182,3 | 26,48 | 94 | |

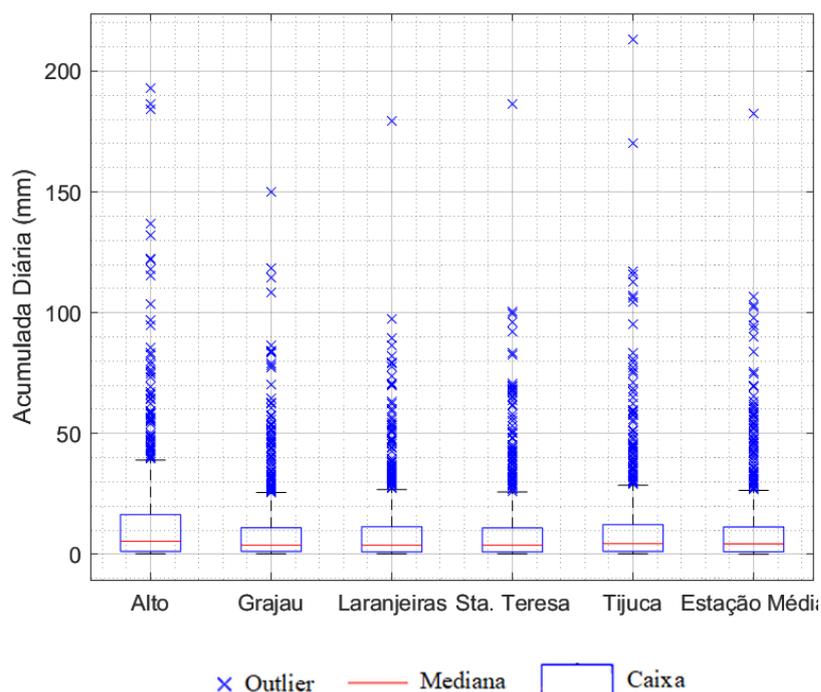


Figura 50 – Diagrama de Caixa – Estações pluviométricas e Estação Média

3.3.1.3. Enfoque 3: Precipitação Diária com Movimentos de Massa - Estações Pluviométricas

Para desenvolvimento da análise estatística descritiva, adota-se a acumulada diária (mm) na data de ocorrência dos movimentos de massa. Ainda, conforme indicado no item 3.2, além da estruturação dos dados em função da data, foi necessário averiguar a pertinência da manutenção de cada um dos eventos de movimento. Neste contexto, após a aplicação dos critérios, restaram 33 (trinta e três) movimentos de massa (item 3.2.1.2).

Relativamente a estes movimentos, nas Figura 51 e Figura 52 estão apresentados os gráficos de distribuição de frequência e de dispersão relativos ao 1º intervalo (0-24h).

Ambos os gráficos apresentam os 33 (trinta e três) eventos de acumuladas diárias, entretanto a segregação dos eventos por estação pluviométrica é apresentada apenas no gráfico de dispersão (Figura 52). Os resultados mostram que:

- I. As dispersões dos eventos de precipitação (Figura 52) sinaliza haver tendência de aumento de acumuladas diárias com o aumento da duração dos eventos;
- II. 42% (14/33) dos movimentos de massa correspondem às acumuladas diárias menores que 50mm, fato que implica na classificação da precipitação em “Probabilidade Baixa” de ocorrência pelo Sistema Alerta-Rio (Tabela 9);
- III. 75% (25/33) das precipitações diárias foram distribuídas em até 10h de duração;
- IV. A manutenção de movimentos de massa relacionados a acumuladas diárias com magnitudes baixas, ou seja, menores do que os 30mm adotados como referencial pela Geo-Rio, ocorre em função do critério adotado no item (3.2.1.2). Entende-se que a deflagração de movimentos de massa para magnitudes baixas ou posteriores à ocorrência de eventos de precipitação pode estar vinculada à precipitação antecedente, ou ainda, poderia se tratar de incerteza quanto à data efetiva da deflagração do movimento de massa.

Na Tabela 31 são apresentadas as medidas de tendência central e de variação, para o conjunto dos 33 (trinta e três) eventos de acumuladas diárias (Figura 42) relacionadas com movimentos de massa. Adicionalmente, tanto a média quanto a mediana de precipitação diária estão inseridas no intervalo de “Probabilidade Média” do Sistema Alerta-Rio (Tabela 9).

Tabela 31 –Tendência Central e Variação – Acumulada Diária de Movimentos - Estações

| Movimentos | Média (mm) | Mediana (mm) | Desvio (mm) |
|------------|------------|--------------|-------------|
| 33 eventos | 77,6 | 67,2 | 62,7 |

O distanciamento dos valores de mediana e de média caracteriza a assimetria à direita, com a média maior do que a mediana. Os valores de desvio em comparação aos valores da média, refletem a dispersão da distribuição em relação à média e sinalizam a existência de assimetria representativa.

Na Figura 53, tem-se a apresentação conjunta dos diagramas de caixa das acumuladas diárias (mm), a qual permite a comparação dos diagramas das 5 (cinco) estações pluviométricas consideradas para a área de estudo e dos 33 (trinta e três) movimentos de massa.

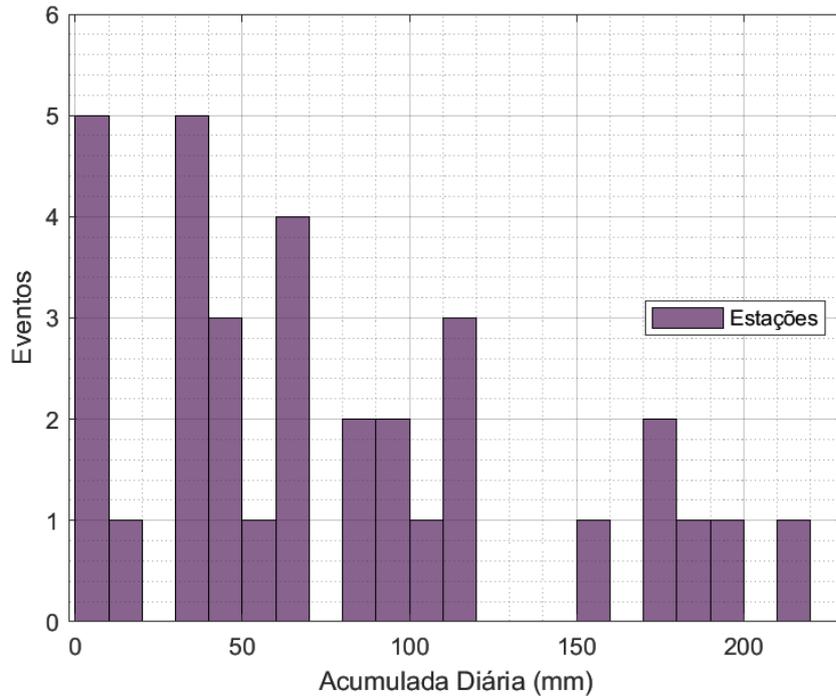


Figura 51 – Histograma – Movimentos de Massa – Estações

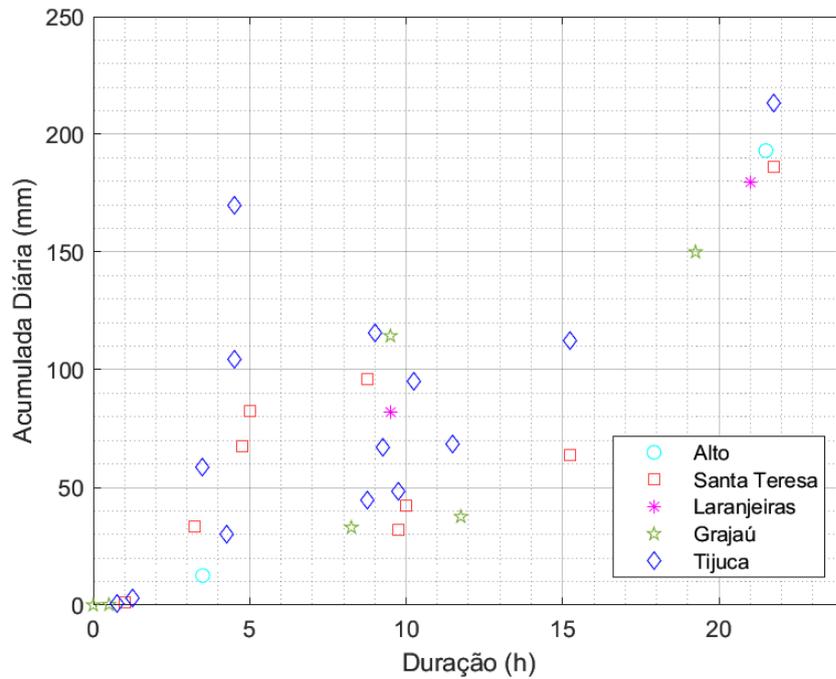


Figura 52 – Dispersão – Movimentos de Massa - Estações

Os elementos que caracterizam a distribuição estatística segundo o diagrama de caixa e o total de eventos computados para cada estação pluviométrica estão resumidos na Tabela 27. Os resultados do diagrama de caixa das precipitações acumuladas diárias nos dias em que ocorreram movimentos de massa mostraram:

- I. O diagrama de acumuladas diárias relacionadas aos 33 (trinta e três) movimentos de massa não apresenta pontos discrepantes, implicando a concentração das acumuladas entre os adjacentes superior e inferior;
- II. O 1º quartil está situado em 32,8mm e o 3º quartil está em 113,0mm (Tabela 32), logo os valores existentes neste intervalo representam 50% dos eventos considerados, ou seja, aproximadamente 16 eventos de precipitação com movimentos de massa.
- III. A caixa e o adjacente superior do diagrama de movimentos de massa estão situados na direção de valores discrepantes dos diagramas das 5 (cinco) estações pluviométricas, implicando que pelo menos 75% das acumuladas diárias (mm) do 1º intervalo se relacionam com eventos discrepantes de precipitação;
- IV. 25% dos eventos de precipitação diária associados a movimentos de massa ocorreram para acumulada relativamente baixas, inferiores a 32,8mm (Tabela 32). Nestes eventos é possível que as rupturas se devam à perda de resistência do solo por infiltração de água relacionadas às precipitações antecedentes à data do movimento e/ou a demais fatores que afetaram a resistência do solo e que não foram considerados neste estudo. Outra alternativa seria a possibilidade de incorreção no boletim de ocorrência quanto à data efetiva da deflagração do movimento de massa.

Na Tabela 32 são apresentadas as medidas de posição relativas ao diagrama de caixa das acumuladas diárias dos movimentos de massa (Figura 53).

Tabela 32 – Medidas de Posição – Movimentos de Massa

| | Quartis (mm) | | | Limites (mm) | | Adjacente (mm) | Registros discrepantes | Total de registros |
|------------|--------------|------------------|----------|--------------|--------|----------------|------------------------|--------------------|
| | 1º (25%) | 2º Mediana (50%) | 3º (75%) | Mínimo | Máximo | Superior | Superior | |
| Movimentos | 32,8 | 67,2 | 113,0 | 0,0 | 213,2 | 213,2 | 0 | 33 |

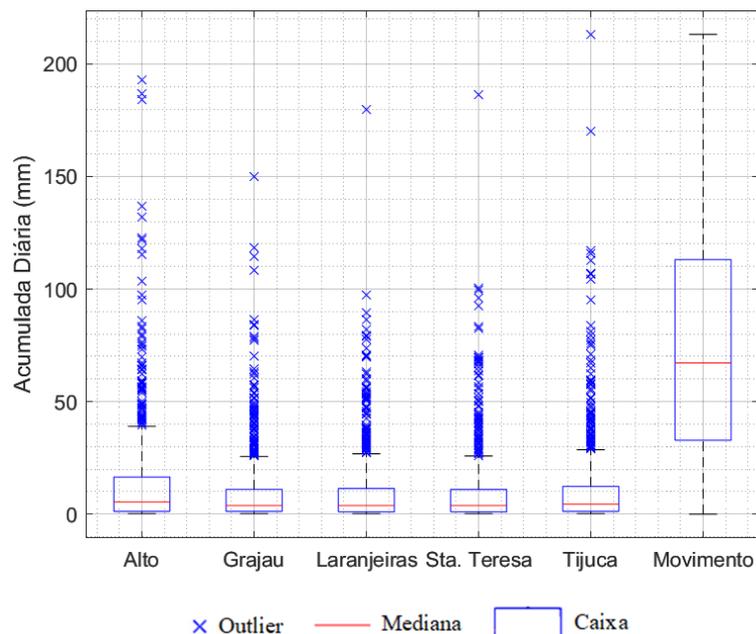


Figura 53 – Diagrama de Caixa – Estações pluviométricas e movimentos de massa

3.3.1.4. Enfoque 4: Precipitação Diária com Movimentos de Massa - Estação Média

Para desenvolvimento da análise estatística descritiva, adota-se a acumulada diária (mm) na data de ocorrência dos movimentos de massa. Ainda, conforme indicado no item 3.2, além da estruturação dos dados em função da data, foi necessário averiguar a pertinência da manutenção de cada um dos eventos de movimento. Neste contexto, após a aplicação dos critérios (item 3.2.2), restaram 21 (vinte e um) movimentos de massa (Figura 43) relacionados à Estação Média.

Relativamente a tais movimentos, nas Figura 54 e Figura 55 estão apresentados os gráficos de distribuição de frequência e a dispersão das acumuladas diárias da Estação Média para as datas de ocorrência dos 21 (vinte e um) movimentos de massa. Os resultados mostram que:

- I. As dispersões dos eventos de precipitação (Figura 55) sinaliza haver tendência de aumento de acumuladas diárias com o aumento da duração dos eventos;
- II. 57% (12/21) dos movimentos de massa correspondem às acumuladas diárias menores que 50mm, fato que implica em sua classificação em “Probabilidade Baixa” de ocorrência do Sistema Alerta-Rio (Tabela 9);
- III. 86% (18/21) das precipitações diárias foram distribuídas em até 10h de duração;

- IV. A manutenção de movimentos de massa relacionados a acumuladas diárias com magnitudes baixas, ou seja, menores do que os 30mm adotados como referencial pela Geo-Rio, ocorre em função do critério adotado no item (3.2.2.2). Entende-se que a deflagração de movimentos de massa para magnitudes baixas ou posteriores à ocorrência de eventos de precipitação pode estar vinculada à precipitação antecedente, ou ainda, poderia se tratar de incerteza quanto à data efetiva da deflagração do movimento de massa.

Ainda, comparando-se as Figura 52 e Figura 55, tem-se que :

- V. A maior acumulada diária da Estação Média relacionada a movimentos de massa (Figura 55) é 182,3mm, enquanto para as estações pluviométricas (Figura 52) a maior acumulada diária é 213,2mm;
- VI. Para a Estação Média, 57% dos eventos correspondem a acumuladas diárias inferiores a 50mm, enquanto para estações pluviométricas (Figura 52) a proporção é 42% dos eventos. Esta pequena discrepância está relacionada à tendência de os valores de acumulada das estações Grajaú, Santa Teresa e Laranjeiras abaterem as maiores acumuladas diárias da estações Tijuca e Alto da Boa vista.
- VII. A manutenção de movimentos de massa relacionados a acumuladas diárias com magnitudes baixas, ou seja, menores do que os 30mm adotados como referencial pela Geo-Rio, ocorre em função do critério adotado no item (3.2.2.2). Estes movimentos podem estar relacionados à precipitação antecedente, e/ou a demais fatores que afetaram a resistência do solo e que não foram considerados neste estudo. Outra alternativa seria a possibilidade de incorreção no boletim de ocorrência quanto à data efetiva da deflagração do movimento de massa.

Ademais, na Tabela 33 são apresentadas as medidas de tendência central e de variação, para o conjunto dos 21 (vinte e um) eventos de acumuladas diárias relacionadas com movimentos de massa. Adicionalmente, tanto a média quanto à mediana de precipitação diária estão inseridas no intervalo de “Probabilidade Média” do Sistema Alerta-Rio (Tabela 9).A assimetria à direita é caracterizada pelo distanciamento dos valores de mediana e de média, em que a média é maior do que a mediana. Os valores de desvio refletem a dispersão da distribuição em relação à média e sinalizam a existência de assimetria representativa.

Tabela 33 – Tendência Central e de Variação – Movimentos – Estação Média

| Movimentos | Média (mm) | Mediana (mm) | Desvio (mm) |
|------------|------------|--------------|-------------|
| 21 eventos | 52,4 | 46,0 | 46,1 |

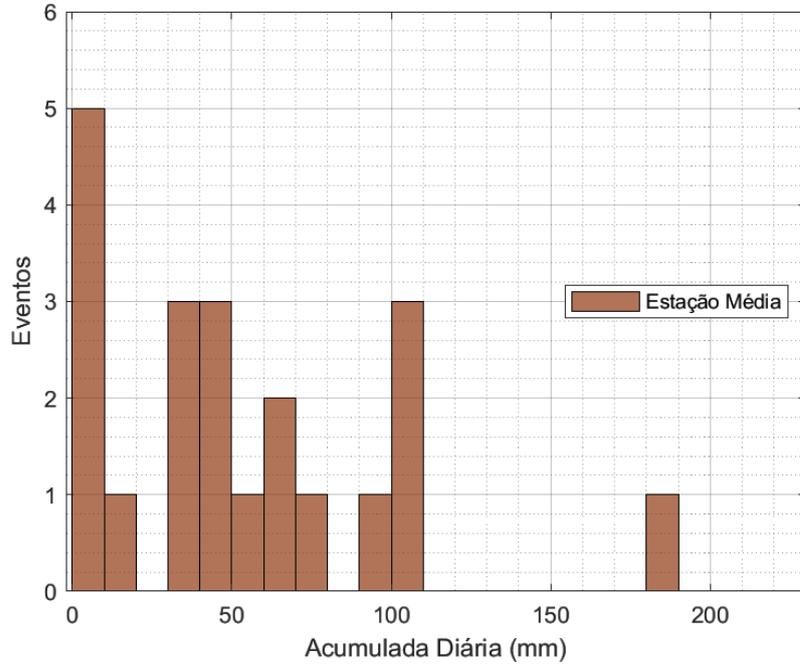


Figura 54 – Histograma – Movimentos de Massa 1º Intervalo – Estação Média

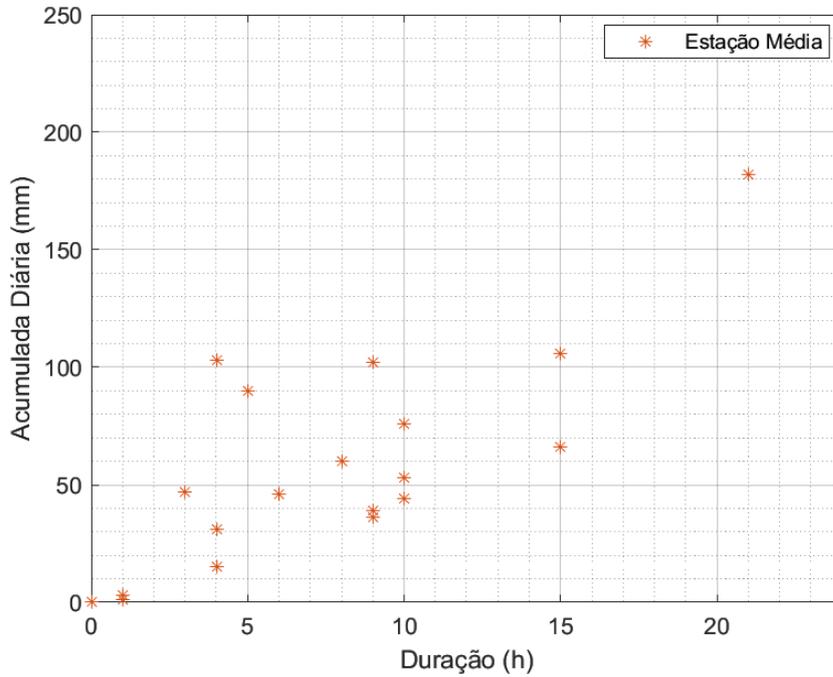


Figura 55 – Dispersão Acumulada Diária e Duração – Movimentos de Massa – Estação Média

Na Figura 56, tem-se, conjuntamente, os diagramas de caixa das acumuladas diárias (mm) da Estação Média e dos 21 (vinte e um) movimentos de massa. Os elementos que caracterizam a distribuição estatística, segundo o diagrama de caixa, e o total de eventos computados para a Estação Média estão resumidos na Tabela 30.

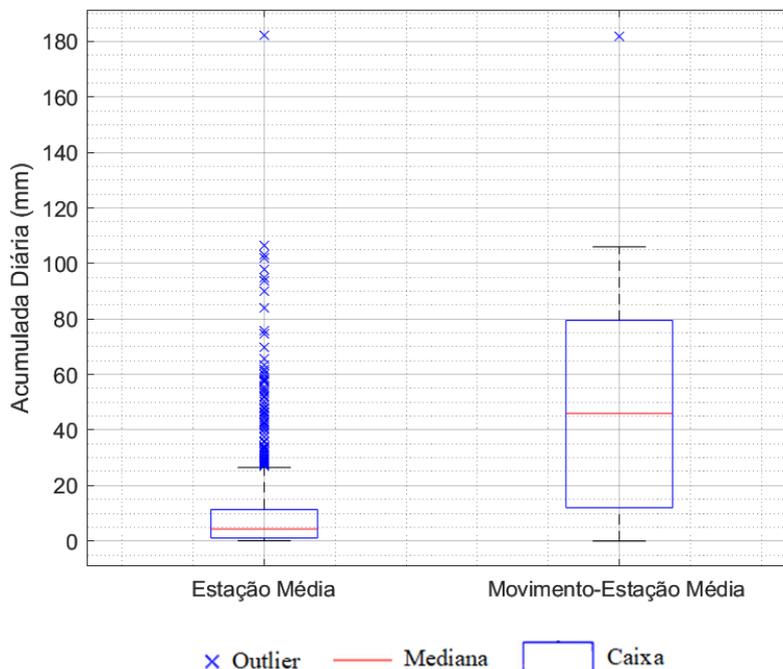


Figura 56 – Diagrama de Caixa – Estação Média e Movimentos de Massa

Os resultados (Tabela 34) do diagrama de caixa das precipitações acumuladas diárias nos dias em que ocorreram movimentos de massa mostraram:

- I. Diferentemente do que ocorre na Figura 53, em que a caixa dos movimentos de massa está na direção dos valores discrepantes, na Figura 56 a caixa está deslocada para baixo, indicando diminuição das magnitudes das acumuladas diárias relacionadas aos movimentos de massa;
- II. No diagrama de movimentos da Figura 56, o 1º quartil está situado em 12 mm e o 3º quartil está em 79,5mm. Tem-se que todos os valores existentes neste intervalo representam 50% dos eventos considerados, ou seja, aproximadamente 11 eventos de precipitação com movimentos de massa.
- III. No diagrama de movimentos da Figura 53, o 1º quartil está situado em 32,8mm e o 3º quartil está em 113,0mm (Tabela 32), logo os valores existentes neste intervalo representam 50% dos eventos considerados, ou seja, aproximadamente 16 eventos de precipitação com movimentos de massa.

- IV. No diagrama de movimentos da Figura 56, uma parcela dos eventos que compõem a caixa, a mediana e o adjacente superior estão situados na região de valores discrepantes da Estação Média;
- V. Há um elemento discrepante no diagrama de movimentos da Estação Média (Figura 56), significa que mesmo dentro do conjunto de dados de movimentos de massa esta magnitude de precipitação é discrepante;

Ainda, na Figura 57, são apresentados conjuntamente os diagramas de caixa das acumuladas diárias (mm) da referentes aos 21 (vinte e um) movimentos de massa da Estação Média e aos 33 (trinta e três) movimentos de massa (item 3.3.1.3). Tem-se que:

- VI. A consideração de valores médios, como ocorre para a Estação Média, abate as acumuladas extremas e concentra 50% dos eventos no intervalo entre 12mm e 79,5mm e indica o valor de 182,3mm como discrepante. Em diferenciação, a adoção das acumuladas das estações, relaciona 50% das ocorrências de movimentos de massa ao intervalo entre 32,8mm e 113mm.

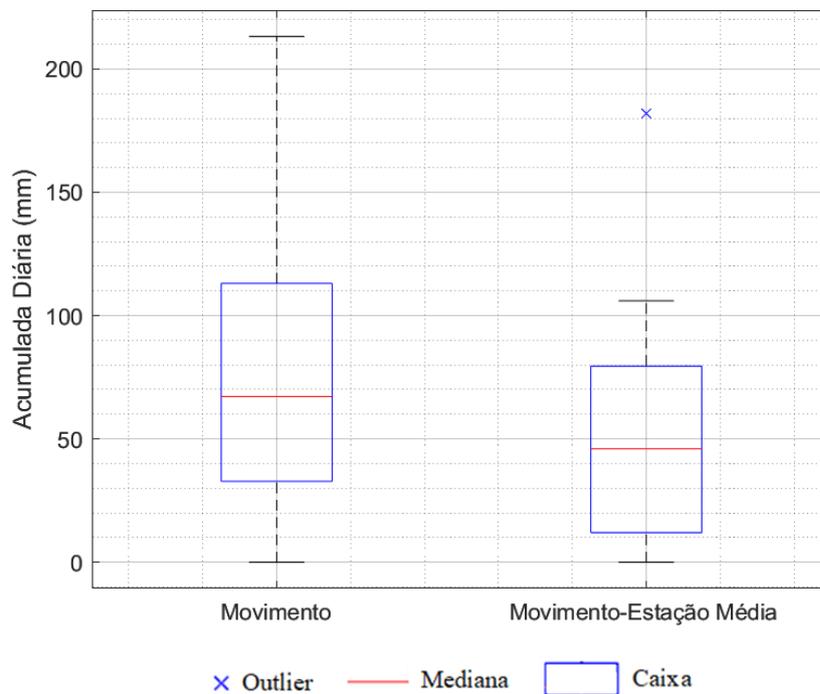


Figura 57 – Diagrama de Caixa – Conjuntos de movimentos de massa

Ademais, na Tabela 34, tem-se as medidas relativas ao diagrama de caixa das acumuladas diárias dos movimentos de massa vinculados à Estação Média.

Tabela 34 – Medidas de Posição – Movimentos de Massa – Estação Média

| | Quartis (mm) | | | Limites (mm) | | Adjacente (mm) | Registros discrepante | Total de registros |
|-----------------------------|--------------|------------------|----------|--------------|--------|----------------|-----------------------|--------------------|
| | 1º (25%) | 2º Mediana (50%) | 3º (75%) | Mínimo | Máximo | Superior | Superior | |
| Movimentos da Estação Média | 12 | 46 | 79,5 | 0,0 | 182,3 | 106 | 1 | 21 |

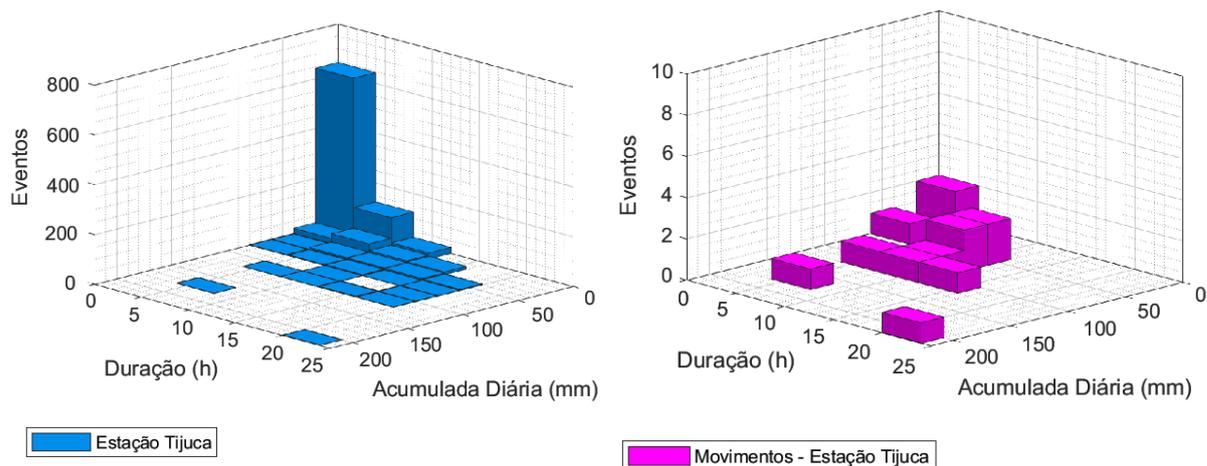
3.3.2 Estatística Inferencial – Teorema de Bayes

O teorema de Bayes permite o cálculo da probabilidade de ocorrência de um evento A considerando que um evento B ocorreu. Deste modo, uma vez que sejam conhecidas as probabilidades a priori, marginal e condicional, é possível aplicá-lo para obtenção da probabilidade a posteriori de deflagração de movimentos de massa dada a ocorrência de eventos de precipitação.

A seguir, o teorema de Bayes foi aplicado ao conjunto de dados originados das estações pluviométricas tomadas individualmente (Tijuca, Alto da Boa Vista, Grajaú, Laranjeiras e Santa Teresa - Figura 40) e, também, ao conjunto de dados gerado pela média dos registros das 5 estações pluviométricas (Estação Média).

3.3.2.1. Estações Tijuca, Alto da Boa Vista, Grajaú, Laranjeiras e Santa Teresa

A análise probabilística para a área de estudo foi desenvolvida individualmente para as estações Tijuca, Santa Teresa, Grajaú, Alto da Boa Vista e Laranjeiras (Figura 42). Nas Figura 58 estão apresentados os histogramas dos eventos de precipitação não relacionados a movimentos de massa (Figura 58a) e dos eventos relacionados a movimentos de massa (Figura 58b) da estação Tijuca.



a) todos os eventos de precipitação

(b) eventos com movimento de massa

Figura 58 – Dispersão Acumulada Diária e Duração – Estação Tijuca

Na Tabela 35 estão apresentados os valores de frequência para as classes dos histogramas (Figura 58) que embasam o cálculo das probabilidades condicional, a priori, marginal e a posteriori da estação Tijuca. O total de eventos de precipitação da estação Tijuca é igual ao apresentado na Tabela 25, enquanto o total de eventos com movimentos de massa corresponde ao descrito na Tabela 20.

Tabela 35 – Precipitação da Estação Tijuca- 2009 a 2015

| Acumulada diária (mm) | Duração (h) | | | | | | | | | | | |
|-----------------------|------------------|-----|------|-------|-------|------|--------------------------------|-----|------|-------|-------|-------|
| | Todos os eventos | | | | | | Eventos com movimento de massa | | | | | |
| | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 0-24 | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 20-24 |
| 0-20 | 644 | 125 | 24 | - | - | - | 2 | - | - | - | - | - |
| 20-40 | 23 | 42 | 15 | 11 | - | - | - | 1 | - | - | - | - |
| 40-60 | 2 | 9 | 8 | 7 | 4 | - | - | 1 | 2 | - | - | - |
| 60-80 | 2 | 3 | 4 | 1 | 1 | - | - | - | 2 | - | - | - |
| 80-100 | - | - | 1 | - | 2 | - | - | - | 1 | - | - | - |
| 100-120 | - | 1 | 1 | 3 | 1 | - | - | 1 | 1 | 1 | - | - |
| 120-140 | - | - | - | - | - | - | - | - | - | - | - | - |
| 140-160 | - | - | - | - | - | - | - | - | - | - | - | - |
| 160-180 | - | 1 | - | - | - | - | - | 1 | - | - | - | - |
| 180-200 | - | - | - | - | - | - | - | - | - | - | - | - |
| 200-220 | - | - | - | - | - | 1 | - | - | - | - | - | 1 |
| Total | 936 | | | | | | 14 | | | | | |

O método de cálculo das probabilidades a posteriori, tal como foi efetuado para a Estação Tijuca, foi replicado para as estações Alto da Boa Vista, Grajaú, Laranjeiras e Santa Teresa. As tabelas com os valores de frequência de eventos de precipitação destas 4 (quatro) estações, com e sem movimentos de massa, estão no APÊNDICE B.

Deste modo, seguem na Figura 59 as probabilidades a posteriori das 5 (cinco) estações consideradas. Além da apresentação das probabilidades a posteriori em formato de barras, na Figura 59 estão destacados, no plano de fundo do gráfico, os intervalos de probabilidade média, alta e muito alta (Tabela 9) adotados como critérios operacionais pela Geo-Rio.

Adicionalmente, a partir das probabilidades a posteriori de cada estação, foi gerada Tabela 36 para fins de visualização conjunta das estações que compõem a área de estudo. Para cada intervalo de classe de duração (h) são apresentados os valores de probabilidade a posteriori para cada uma das (cinco) estações. Assim, é possível a verificação do comportamento da área de estudo como um todo e, também, a comparação com os valores de probabilidades a posteriori obtidos para a Estação Média (Figura 61).

Em complementação e a título de exemplo, apresenta-se, como Nota, o cálculo da probabilidade a posteriori $P(A|B1, C1)$ para a Estação Tijuca, considerando o intervalo de chuva acumulada diária B1 (0-20mm) e duração C1 (0-4h)¹:

¹ Nota:

$$P(A|B1, C1) = \frac{(0,14 \cdot 0,015)}{0,69} = 0,31\%$$

onde

$P(B1, C1|A)$ = Probabilidade condicional ou verossimilhança de B1, C1 dada a ocorrência de A. Pode-se traduzir como a probabilidade de se observar movimento de massa para a magnitude de precipitação B1, C1 quando movimentos de massa ocorrem e seu valor é obtido a partir da razão entre a quantidade de movimentos de massa que ocorreram para a magnitude B1, C1 e a quantidade total de movimentos de massa deflagrados.

$$P(B1, C1|A) = \frac{2}{14} = 0,14$$

$P(A)$: Probabilidade a priori de A, que é a probabilidade de um movimento de massa ocorrer independentemente das magnitudes B,C, cujo cálculo é efetuado por meio da razão entre a quantidade de eventos de precipitação que relacionados a movimentos de massa e a quantidade total de eventos de precipitação.

$$P(A) = \frac{14}{936} = 0,015$$

$P(B1, C1)$: Probabilidade marginal de B1, C1, sendo a probabilidade de se observar um evento de precipitação de magnitude B1, C1 em relação a quantidade total de eventos de precipitação.

$$P(B1, C1) = \frac{644}{936} = 0,69$$

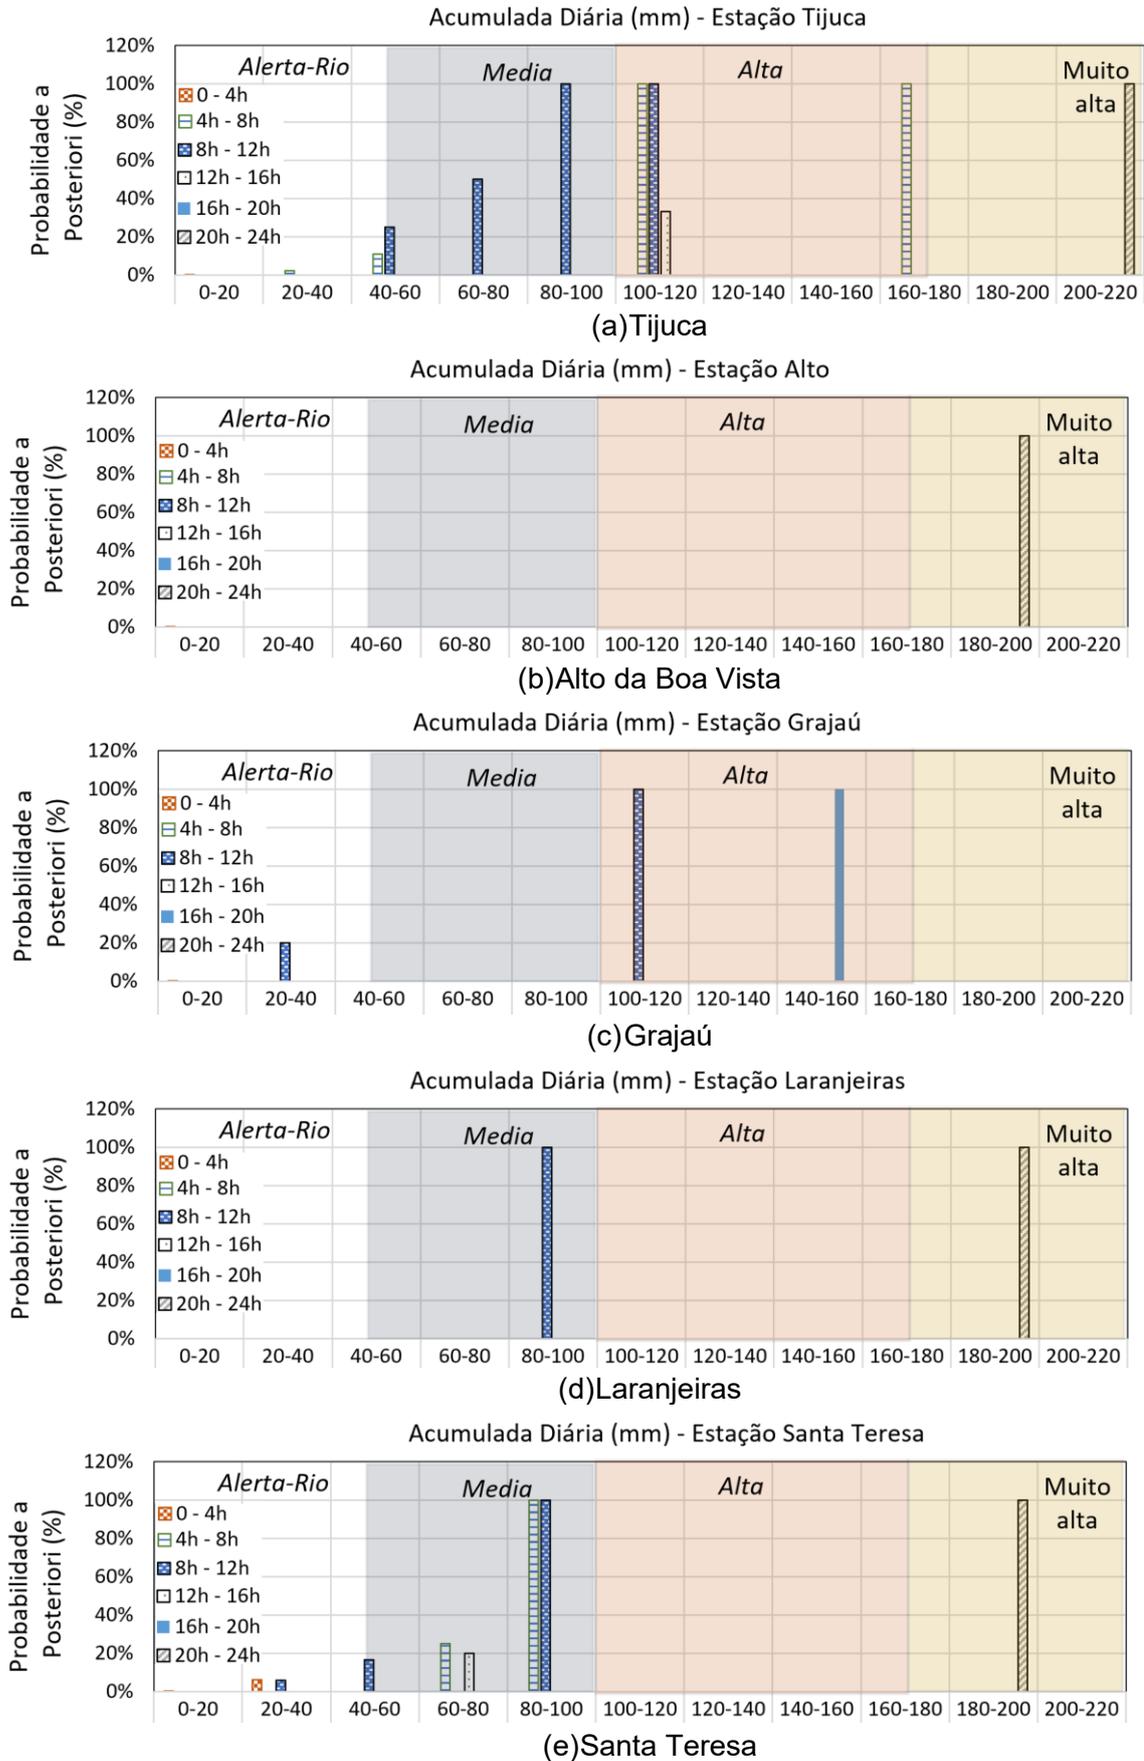


Figura 59 – Probabilidades a Posteriori e do Alerta-Rio - Estações 2009 a 2015

Tabela 36 – Probabilidade a Posteriori – Compilação Estações

| Eixos | Y - Duração (h) | | | | | | | | | | | | | | |
|---------|-----------------|-----------|-----------|-------------|--------------|------------|----------|----------|-------------|--------------|-----------|----------|-----------|-------------|--------------|
| | 0-4h | | | | | 4-8h | | | | | 8-12h | | | | |
| | Tijuca | Alto | Grajaú | Laranjeiras | Santa Teresa | Tijuca | Alto | Grajaú | Laranjeiras | Santa Teresa | Tijuca | Alto | Grajaú | Laranjeiras | Santa Teresa |
| 0-20 | 0,31 % | 0,18 % | 0,31 % | 0,0 % | 0,15 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % |
| 20-40 | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 6,25 % | 2,38 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 20,0 % | 0,0 % | 5,88 % |
| 40-60 | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 11,11 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 25,0 % | 0,0 % | 0,0 % | 0,0 % | 16,67 % |
| 60-80 | 0,0 % | - | 0,0 % | - | - | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 25,0 % | 50,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % |
| 80-100 | - | 0,0 % | - | 0,0 % | - | - | 0,0 % | 0,0 % | 0,0 % | 100 % | 100 % | - | 0,0 % | 100 % | 100 % |
| 100-120 | - | - | 0,0 % | - | 0,0 % | 100 % | - | - | - | - | 100 % | 0,0 % | 100 % | - | - |
| 120-140 | - | - | - | - | - | - | 0,0 % | - | - | - | - | 0,0 % | - | - | - |
| 140-160 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 160-180 | - | - | - | - | - | 100 % | - | - | - | - | - | - | - | - | - |
| 180-200 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 200-220 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - |

(a tabela continua)

| Eixos | Y - Duração (h) | | | | | | | | | | | | | | |
|---------|-----------------|-------|--------|-------------|--------------|--------|-------|--------|-------------|--------------|--------|-------|--------|-------------|--------------|
| | 12-16h | | | | | 16-20h | | | | | 20-24h | | | | |
| | Tijuca | Alto | Grajaú | Laranjeiras | Santa Teresa | Tijuca | Alto | Grajaú | Laranjeiras | Santa Teresa | Tijuca | Alto | Grajaú | Laranjeiras | Santa Teresa |
| 0-20 | - | 0,0 % | 0,0 % | 0,0 % | 0,0 % | - | - | - | 0,0 % | - | - | - | - | - | - |
| 20-40 | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | - | 0,0 % | 0,0 % | 0,0 % | 0,0 % | - | - | - | - | - |
| 40-60 | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | - | 0,0 % | - | - | - |
| 60-80 | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 20,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | 0,0 % | - | 0,0 % | - | 0,0 % | 0,00 % |
| 80-100 | - | 0,0 % | - | 0,0 % | 0,0 % | 0,0 % | 0,0 % | - | - | 0,0 % | - | - | - | - | - |
| 100-120 | 33,33 % | 0,0 % | 0,0 % | - | - | 0,0 % | - | - | - | - | - | 0,0 % | - | - | - |
| 120-140 | - | - | - | - | - | - | 0,0 % | - | - | - | - | 0,0 % | - | - | - |
| 140-160 | - | - | - | - | - | - | - | 100 % | - | - | - | - | - | - | - |
| 160-180 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 180-200 | - | 0,0 % | - | - | - | - | 0,0 % | - | - | - | - | 100 % | - | 100 % | 100 % |
| 200-220 | - | - | - | - | - | - | - | - | - | - | 100 % | - | - | - | - |

(conclusão da tabela)

As probabilidades foram calculadas em função de módulo de referência temporal diário (24h). Isto implica que, se nas últimas 24h houve precipitação de acumulada entre 40-60 mm com duração média entre 8-12h, a probabilidade de ocorrência de movimento de massa varia de 0% a 25% (Tabela 36).

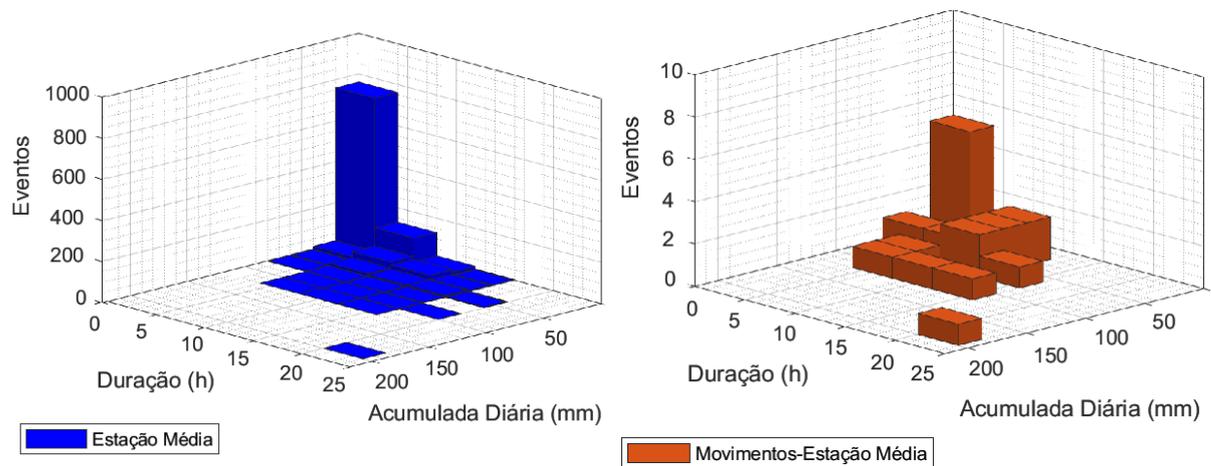
Para classes em que a Tabela 36 não indica probabilidade a posteriori. Deve-se, nesta situação, tomar como referência outros intervalos de duração para uma mesma acumulada, tal como os intervalos de 8 a 12h, com 100% de probabilidade a posteriori, ou de 12 a 16h, com 33% de probabilidade a posteriori.

Considerando-se os valores de probabilidade a posteriori da Figura 59 e da Tabela 36, tem-se:

- I. Observa-se expressiva relação entre a magnitude/duração de precipitação e a ocorrência de movimento de massa. As probabilidades se tornam mais significativas, maiores ou iguais a 25%, para acumuladas superiores a 40mm com duração maior ou igual a 8h e acumuladas superiores a 60mm com duração maior ou igual a 4h, classes estas que correspondem a risco médio no sistema Alerta Rio.
- II. A maioria das classes indica probabilidade de 100% para acumuladas acima de 80mm com duração maior ou igual a 4h;
- III. Células cujos valores de probabilidade é 0,00%, decorrem do fato de não terem sido observados movimento de massa que preenchessem estes campos para o período estudado. Células com “zero” caracterizam a inexistência de eventos de precipitação para a classe. Nestes casos, pode-se adotar como referência probabilidades a posteriori de classes próximas ao intervalo requerido;
- IV. A pouca quantidade de dados relativos às estações do Alto da Boa Vista, Grajaú e Laranjeiras limita a realização de comparações com as demais estações (Tabela 20).

3.3.2.2. Estação Média

A análise probabilística para a área de estudo foi, também, desenvolvida considerando-se a Estação Média (Figura 43), a partir da qual foram gerados os histogramas dos eventos de precipitação não relacionados a movimentos de massa (Figura 60a) e dos eventos relacionados a movimentos de massa (Figura 60b) cujas amplitudes de classe são 20mm para o atributo/fator acumulada diária (mm) e 4h para o atributo/fator duração (h).



a) todos os eventos de precipitação

(b) eventos com movimento de massa

Figura 60 – Histograma 3D – Estação Média 2009 a 2015

Na Tabela 37 estão apresentados os valores de frequência para as classes dos histogramas (Figura 60) que embasam o cálculo das probabilidades condicional, a priori, marginal e a posteriori. O total de eventos de precipitação da Estação Média é igual ao apresentado na Tabela 28, enquanto o total de eventos com movimentos de massa corresponde ao descrito na Tabela 23.

Tabela 37 – Precipitação da Estação Média- 2009 a 2015

| Acumulada diária (mm) | Duração (h) | | | | | | | | | | | |
|-----------------------|------------------|-----|------|-------|-------|------|--------------------------------|-----|------|-------|-------|-------|
| | Todos os eventos | | | | | | Eventos com movimento de massa | | | | | |
| | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 0-24 | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 20-24 |
| 0-20 | 761 | 129 | 16 | 3 | - | - | 5 | 1 | - | - | - | - |
| 20-40 | 16 | 41 | 27 | 6 | - | - | - | 1 | 2 | - | - | - |
| 40-60 | 3 | 13 | 8 | 9 | 3 | - | 1 | 1 | 2 | - | - | - |
| 60-80 | 2 | 2 | 2 | 3 | - | - | - | - | 2 | 1 | - | - |
| 80-100 | - | 1 | 1 | 2 | 1 | - | - | 1 | - | - | - | - |
| 100-120 | - | 1 | 1 | 1 | - | - | - | 1 | 1 | 1 | - | - |
| 120-140 | - | - | - | - | - | - | - | - | - | - | - | - |
| 140-160 | - | - | - | - | - | - | - | - | - | - | - | - |
| 160-180 | - | - | - | - | - | - | - | - | - | - | - | - |
| 180-200 | - | - | - | - | - | 1 | - | - | - | - | - | 1 |
| 200-220 | - | - | - | - | - | - | - | - | - | - | - | - |
| Total | 1053 | | | | | | 21 | | | | | |

Na Figura 61 são apresentados os valores de probabilidade a posteriori para a Estação Média. Além da apresentação das probabilidades a posteriori em formato de barras, na Figura 61 estão destacados, no plano de fundo do gráfico, os intervalos de probabilidade média, alta e muito alta (Tabela 9) adotados como critérios operacionais pela Geo-Rio.

As probabilidades (Figura 61) foram calculadas em função de módulo de referência temporal diário (24h). Isto significa que, se nas últimas 24h houve precipitação de acumulada média entre 40-60 mm com duração média entre 8-12h, a probabilidade de ocorrência de movimento de massa é 25%.

Para fins de exemplo, a partir da aplicação da Equação 4, tem-se na Nota ² os cálculos relativos à precipitação de acumulada diária na faixa 0-20mm, com duração média entre 0-4h.

² Nota:

$$P(A \setminus B1, C1) = \frac{(0,24 * 0,02)}{0,72} = 0,66\%$$

onde

$P(B1, C1 \setminus A)$ = Probabilidade condicional ou verossimilhança de B1, C1 dada a ocorrência de A. Pode-se traduzir como a probabilidade de se observar movimento de massa para a magnitude de precipitação B1, C1 quando movimentos de massa ocorrem e seu valor é obtido a partir da razão entre a quantidade de movimentos de massa que ocorreram para a magnitude B1, C1 e a quantidade total de movimentos de massa deflagrados.

$$P(B1, C1 \setminus A) = \frac{5}{21} = 0,24$$

$P(A)$: Probabilidade a priori de A, que é a probabilidade de um movimento de massa ocorrer independentemente das magnitudes B,C, cujo cálculo é efetuado por meio da razão entre a quantidade de eventos de precipitação que relacionados a movimentos de massa e a quantidade total de eventos de precipitação.

$$P(A) = \frac{21}{1053} = 0,02$$

$P(B1, C1)$: Probabilidade marginal de B1, C1, sendo a probabilidade de se observar um evento de precipitação de magnitude B1, C1 em relação a quantidade total de eventos de precipitação.

$$P(B1, C1) = \frac{761}{1053} = 0,72$$

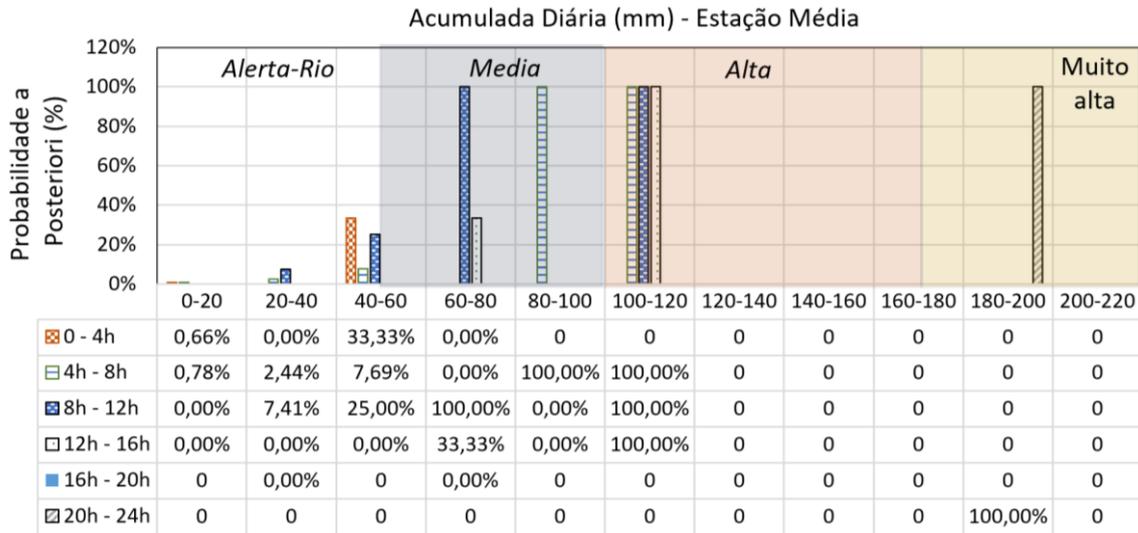


Figura 61 – Probabilidades a Posteriori e do Alerta-Rio - Estação Média 2009 a 2015

Considerando-se os valores de probabilidade a posteriori da Figura 61, verifica-se:

- I. Expressiva relação entre a magnitude/duração de precipitação e a ocorrência de movimento de massa. As probabilidades se tornam mais significativas para acumuladas superiores a 40mm, as quais correspondem a risco médio no sistema Alerta Rio. Acima de 60mm, a maioria das classes indica probabilidade de 100% para eventos com duração maior ou igual a 8h;
- II. Células cujos valores de probabilidade é 0,00%, decorrem do fato de não terem sido observados movimento de massa que preenchessem estes campos para o período estudado. Células com “zero” caracterizam a inexistência de eventos de precipitação para a classe.

3.3.2.3. Análise Comparativa - Estação Média vs Estações Tijuca, Alto da Boa Vista, Grajaú, Laranjeiras e Santa Teresa

Confrontando-se a probabilidade a posteriori da Estação Média (Figura 61) com as probabilidades a posteriori obtidas individualmente para cada uma das 5(cinco) estações (Figura 59 e Tabela 36), observa-se que:

- I. Para a Estação Média (Figura 61) e para a compilação das estações (Tabela 36), acumuladas diárias maiores ou iguais a 80mm com durações maiores ou iguais a 4h apresentaram probabilidade a posteriori de 100%. Aliada à acumulada diária, a duração da precipitação apresentou papel relevante na deflagração de movimentos de massa;

- II. Apenas a Estação Média (Figura 61) apresentou probabilidade a posteriori de 100% para acumuladas diárias de 60mm a 80mm com durações maiores ou iguais a 8h;
- III. Acredita-se que para classe de magnitude (0-20mm) e duração (0h a 4h) baixas, as quais apresentaram probabilidade a posteriori, pode existir uma relação entre os movimentos de massa e a precipitação antecedente;
- IV. A Estação Média, pelo fato de compilar todos dados de movimentos de massa, fornece melhor distribuição das probabilidades a posteriori;
- V. Há que se ressaltar, porém, que os cálculos da Estação Média tendem a reduzir os valores extremos. Por exemplo, para a Estação Média a maior acumulada diária foi 200mm, enquanto na compilação das estações a maior acumulada diárias foi de 220mm. Com isso, a previsão com a Estação Média pode ser classificada como conservadora quando comparada com alguma das estações tomadas individualmente, tal como estação Tijuca.
- VI. A realização de análise comparativa entre o critério do Alerta Rio, que é qualitativo/categórico, e a previsão estatística, que é quantitativa/numérica, requer o estabelecimento de uma relação de correspondência entre ambas as formas de resposta, para que se possa verificar aspectos de convergência e/ou de divergência entre o modelo gráfico e a análise estatística. De qualquer forma, a visualização conjunta de ambos os critérios evidencia alguns aspectos interessantes, tal como ocorre para a estação Tijuca (Figura 59a), em que o risco de ocorrência de movimento de massa é classificado em médio pelo critério Alerta Rio enquanto pelo critério probabilístico há chance de 50% a 100% de ocorrência de movimento.

Tratando-se do aspecto operacional, a segregação de grandes regiões/áreas em zonas menores é prática regular de gerenciamento territorial. Neste caso, a utilização de aspectos que evidenciem comportamento similar ou que caracterize as divergências embasa a segmentação destas regiões. Também a segmentação costuma ser orientada por aspectos de relevo e, sob esta ótica, a área de estudo adotada abrange uma região composta por bacias de drenagem adjacentes (Figura 36).

Do ponto de vista probabilístico, a Estação Média pode ser considerada conservadora. O fato de ela utilizar a média das precipitações (item 3.2) representa uma simplificação que propicia maior praticidade ao desenvolvimento dos modelos e, também, em termos operacionais. Sendo assim, entende-se que a utilização da Estação Média é uma opção viável, principalmente quando são ponderados, conjuntamente com as análises estatísticas, os seguintes elementos:

- Realiza segmentação da atual zona de alerta (Tabela 18);
- Permite maior praticidade no gerenciamento das zonas, uma vez que o gerenciamento de 5 (cinco) regiões menores e adjacentes pode representar um desafio para as estruturas operacionais de controle e de suporte;
- Propicia maior eficiência no desenvolvimento de modelos. Em vez de um modelo para cada uma das 5 (cinco) estações, desenvolve-se um modelo para a Estação Média.

3.4 Estruturação de Dados

Considerando-se as análises realizadas no item 3.3, os dados resultantes do pré-processamento da Estação Média (item 3.2) foram utilizados para composição dos intervalos 1º a 4º da MP01 e os intervalos 1º e 2º da MP02, conforme descrito a seguir.

3.4.1 Modulação de Precipitação

Os estudos de correlação desenvolvidos por Tatizana *et al.* (1987), para a Serra do Mar, com objetivo de desenvolvimento de limiar pluviométrico que diferenciasse eventos de precipitação com e sem registro de movimentos de massa, levaram à conclusão de que as relações precipitação e movimentos de massa eram mais bem caracterizadas quando foram considerados 4 dias (96h) de precipitação acumulada.

De modo análogo, outras correlações foram desenvolvidas tomando-se em consideração a influência da chuva antecedente, tal como realizado por Lumb (1975), Pun *et al.* (2003), Hassan (2018) e Dikshit *et al.* (2020). Ainda, para obtenção de valor crítico de precipitação, na região de Inje na Korea, Lee *et al.* (2016) realizaram estudos que consideravam a precipitação acumulada diária. Seus estudos conduziram ao entendimento de que as precipitações acumuladas diárias referentes à data da ocorrência combinadas com as acumuladas relativas aos 3 dias antecedentes à

ocorrência se mostraram adequadas para a análise probabilística com vistas ao mapeamento das regiões mais suscetíveis aos movimentos de massa.

Em relação à ocorrência do movimento de massa, a condição ideal é identificar não somente a data, mas também o horário exato da ruptura. Entretanto, relativamente aos registros dos movimentos de massa, foram observadas inconsistências quanto à precisão das informações registradas (item 3.4.2.1). Cabe ressaltar que, muitas dessas informações dependem de relato da população local, sem conhecimento técnico, e muitas vezes emocionalmente afetadas pela ocorrência deflagrada.

Sendo assim, dadas as condicionantes para obtenção de referências temporais da ocorrência dos movimentos de massa, principalmente quando se trata de obter o horário dos movimentos, entende-se que tomar como referência a data de deflagração do movimento de massa é uma opção pertinente. Neste caso, contorna-se a limitação de obtenção do horário da ocorrência do movimento.

Nesta tese foi adotada a data de ocorrência do movimento de massa como referência para a contabilização da precipitação ocorrida durante o período de 4 dias (96h), para fins de captar a influência da precipitação que antecede o movimento de massa.

Em termos de discretização temporal e para fins de desenvolvimento de análises comparativas de desempenho, a discretização ocorrerá de duas formas distintas, denominadas Modulação de Precipitação 01 (MP01), conforme Figura 62, e Modulação de Precipitação 02 (MP02), de acordo com a Figura 63.

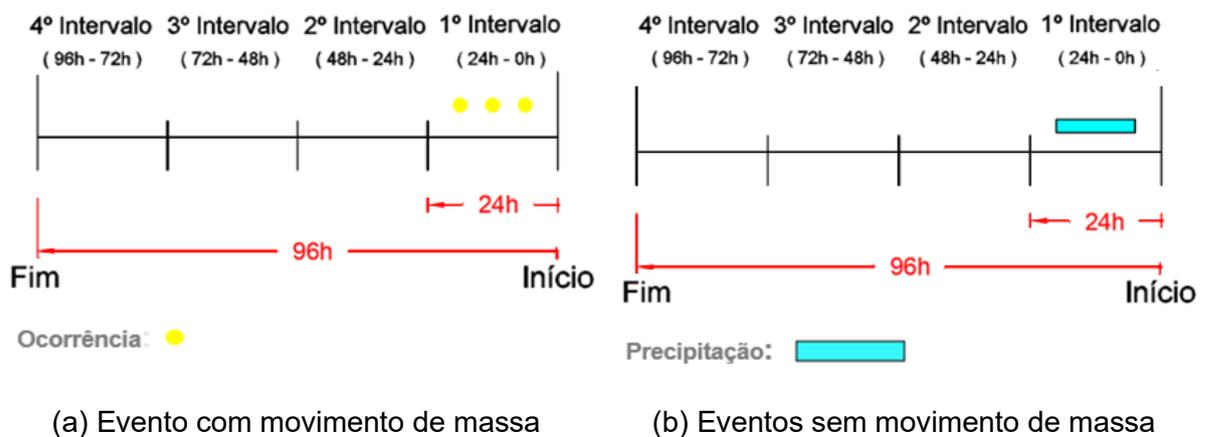
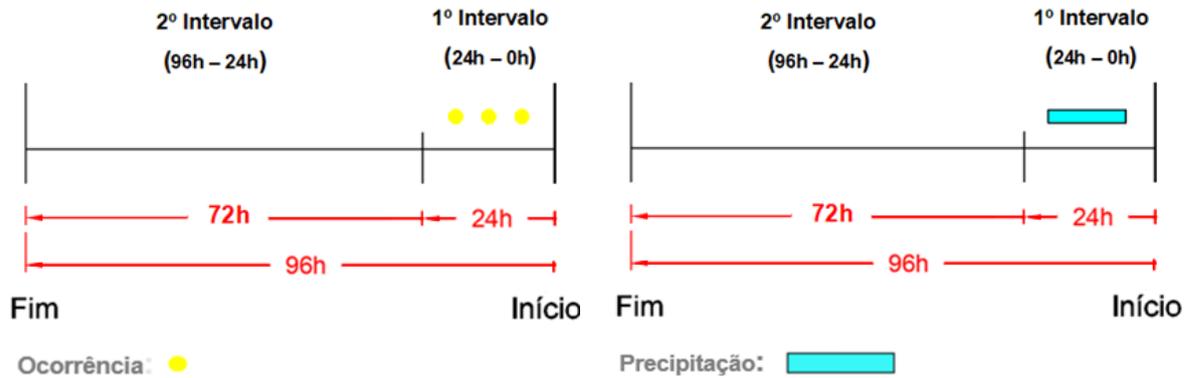


Figura 62 – Bloco de Eventos Pluviométricos – MP01

A MP01 é constituída por 4 (quatro) intervalos consecutivos diários (24h), conforme indicado nos esquemas (a) e (b) da Figura 62. O 1º. intervalo corresponde à data do movimento de massa e os demais representam os dias antecedentes. Cada intervalo é representado por 2 (dois) atributos, acumuladas diárias (mm) e duração da precipitação (h). Desta forma, os dados de entrada da MP01 são representados por 8 (oito) atributos no total.



(a) Evento com movimento de massa (b) Eventos sem movimento de massa

Figura 63 – Bloco de Eventos Pluviométricos – MP02

A MP02 é composta por 2 (dois) intervalos que juntos representam 96h, o 1º (um) intervalo inclui 24h e 2º (um) intervalo contempla 72h. Para fins de melhor caracterização da MP02, seguem, na Figura 63, os esquemas (a) e (b) de eventos com e sem ocorrência de movimento de massa.

O 1º intervalo corresponde à data do movimento de massa e 2º intervalo é obtido a partir do somatório das acumuladas diárias dos 3 (três) dias anteriores à data de referência. Cada intervalo é representado por 2 (dois) atributos, acumuladas diárias (mm) e duração da precipitação (h), contabilizando-se 4 (quatro) atributos. Além destes, foi adotado um quinto atributo, denominado fator de distribuição (FD), que representa uma medida quantitativa da relação entre acumulada diária e a expectativa mensal. Assim sendo, o fator de distribuição (FD) foi definido conforme indicado na Equação (13).

$$FD: \frac{\text{Acumulada 1º Intervalo (mm)}}{\text{Expectativa de Acumulada Mensal (mm)}} \quad (13)$$

3.4.2 Dados Pluviométricos – Estação Média

Os atributos representativos dos eventos de precipitação são: 1) Acumuladas Diárias (mm), referentes à modulação temporal de 96h; 2) Duração das Acumuladas Diárias (h); 3) Fator de Distribuição (%). A partir de qualquer data, pode-se preencher as colunas referentes às acumuladas e suas durações.

No caso da MP01 (Figura 62b), o 1º intervalo é preenchido com a acumulada diária (mm) e sua duração (h) na data tomada como referência, os intervalos 2º a 4º caracterizam os 3 (três) dias anteriores à data de referência e representam a precipitação antecedente (Tabela 67).

Tratando-se da MP02 (Figura 63b), o 1º intervalo é preenchido com a acumulada diária (mm) e sua duração (h) na data tomada como referência, o intervalo 2º é obtido a partir do somatório das acumuladas dos 3 (três) dias anteriores à data de referência e representam a precipitação antecedente e o Fator de distribuição é calculado a partir da Equação 13, conforme estruturado na Tabela 68.

No APÊNDICE A são apresentados, em formato tabular, as amostras das MP01 (Tabela 67) e MP02 (Tabela 68) utilizadas como dados de entrada para treinamento, validação e teste dos algoritmos classificadores.

A adoção da combinação dos atributos acumuladas (mm) e duração(h) deu-se pela característica de serem variáveis que apresentam menor grau de dependência entre si, quando comparadas com o atributo intensidade (mm/h), que é obtida em função da acumulada (mm) e da duração (h).

A substituição do atributo intensidade (mm/h) pelo atributo acumulada (mm) em trabalhos recentes caracteriza preferência pela adoção de variáveis admitidas independentes nas análises de correlação de precipitação com movimentos de massa (Melillo *et al.*, 2018, 2014; Peruccacci *et al.*, 2012; Teja *et al.*, 2019; Zhao *et al.*, 2019^a, apud Treesa *et al.*, 2021).

Como a análise foi desenvolvida por meio de aplicação de aprendizado supervisionado, foi necessário fornecer ao algoritmo o rótulo ou a classificação de cada amostra/exemplar que compõe o grupo de dados de entrada. Para este fim, por se tratar de classificação binária, adota-se a classe (1), como evento positivo, que representa casos de precipitação com ocorrência de movimentos de massa, e a classe (0) como evento negativo, que representa eventos de precipitação sem ocorrência de movimentos de massa.

3.4.2.1. Amostras da Classe (1) – Precipitação com Movimentos de Massa

As datas de deflagração dos movimentos de massa são originadas dos boletins de ocorrências de movimentos de massa da Fundação Geo-Rio (item 3.2). Utilizando-se a data de ocorrência do movimento como referência, é possível obter os atributos representativos dos eventos de precipitação relacionados à movimentos de massa, que são: 1) Acumuladas Diárias (mm), referentes às modulações temporais que consideram 96h (4 dias); 2) Duração das Acumuladas Diárias (h); 3) Fator de Distribuição (%).

Logo, a partir da data da ocorrência do movimento de massa, preenchem-se as células referentes às acumuladas e suas durações. O 1º intervalo é preenchido com a acumulada diária (mm) e sua duração (h), considerando-se a data registrada da ocorrência do movimento de massa. Os intervalos 2º a 4º, conforme o tipo de modulação adotada (MP01 ou MP02) caracterizam os 3 (três) dias anteriores à data de ocorrência do movimento de massa e representam a precipitação antecedente (Tabela 38 e Tabela 39).

A Tabela 38, estruturada de acordo com a modulação de precipitação MP01, é composta por todos os eventos de precipitação pertencentes à classe (1). Conforme indicado no item 3.2.2, para a Estação Média, são contabilizados 21 (vinte e um) eventos de precipitação em que houve deflagração de movimentos de massa.

De modo equivalente, a Tabela 39 também é composta por 21 (vinte e um) eventos de precipitação pertencentes à classe (1), entretanto está estruturada em conformidade com a modulação de precipitação MP02.

No APÊNDICE A é apresentado o conjunto completo de dados de entrada utilizados nas análises, o qual contém todos os eventos da classe (0) e da Classe (1) pertencentes às modulações MP01 (Tabela 67) e MP02 (Tabela 68).

Tabela 38. Eventos Precipitação com Movimentos de Massa – MP01

| Referência | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | |
|------------|------------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|
| Estação | Data | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) |
| Média | 04/12/2009 | 66 | 15 | 2 | 1 | 3 | 1 | 0 | 0 |
| Média | 10/12/2009 | 44 | 10 | 57 | 9 | 16 | 13 | 5 | 2 |
| Média | 11/12/2009 | 1 | 1 | 44 | 10 | 57 | 9 | 16 | 13 |
| Média | 30/12/2009 | 53 | 10 | 12 | 3 | 14 | 4 | 24 | 2 |
| Média | 15/01/2010 | 76 | 10 | 20 | 3 | 0 | 0 | 0 | 0 |
| Média | 16/01/2010 | 1 | 1 | 76 | 10 | 20 | 3 | 0 | 0 |
| Média | 06/03/2010 | 90 | 5 | 4 | 2 | 2 | 2 | 3 | 2 |
| Média | 07/03/2010 | 0 | 0 | 90 | 5 | 4 | 2 | 2 | 2 |
| Média | 17/03/2010 | 39 | 9 | 15 | 6 | 5 | 2 | 41 | 5 |
| Média | 05/04/2010 | 102 | 9 | 10 | 2 | 0 | 0 | 0 | 0 |
| Média | 06/04/2010 | 182 | 21 | 102 | 9 | 10 | 2 | 0 | 0 |
| Média | 09/04/2010 | 15 | 4 | 17 | 5 | 24 | 7 | 182 | 21 |
| Média | 25/04/2011 | 103 | 4 | 48 | 4 | 0 | 0 | 0 | 0 |
| Média | 26/04/2011 | 60 | 8 | 103 | 4 | 48 | 4 | 0 | 0 |
| Média | 15/01/2013 | 47 | 3 | 10 | 4 | 0 | 0 | 1 | 1 |
| Média | 17/01/2013 | 31 | 4 | 3 | 2 | 47 | 3 | 10 | 4 |
| Média | 22/01/2013 | 46 | 6 | 32 | 7 | 14 | 3 | 5 | 1 |
| Média | 23/01/2013 | 0 | 0 | 46 | 6 | 32 | 7 | 14 | 3 |
| Média | 18/03/2013 | 36 | 9 | 58 | 7 | 2 | 2 | 5 | 1 |
| Média | 06/12/2013 | 3 | 1 | 63 | 3 | 0 | 0 | 2 | 1 |
| Média | 11/12/2013 | 106 | 15 | 27 | 4 | 0 | 0 | 0 | 0 |

Tabela 39. Eventos Precipitação com Movimentos de Massa – MP02

| Referência | | 1º Intervalo (0-24h) | | 2º Intervalo (24-96h) | | Fator Distribuição 1º Intervalo |
|------------|------------|-------------------------|----------------|--------------------------|----------------|---------------------------------------|
| Estação | Data | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | (%) |
| Média | 04/12/2009 | 66 | 15 | 5 | 2 | 47 |
| Média | 10/12/2009 | 44 | 10 | 78 | 24 | 31 |
| Média | 11/12/2009 | 1 | 1 | 117 | 32 | 1 |
| Média | 30/12/2009 | 53 | 10 | 50 | 9 | 38 |
| Média | 15/01/2010 | 76 | 10 | 20 | 3 | 49 |
| Média | 16/01/2010 | 1 | 1 | 96 | 13 | 1 |
| Média | 06/03/2010 | 90 | 5 | 9 | 6 | 58 |
| Média | 07/03/2010 | 0 | 0 | 96 | 9 | 0 |
| Média | 17/03/2010 | 39 | 9 | 61 | 13 | 25 |
| Média | 05/04/2010 | 102 | 9 | 10 | 2 | 63 |
| Média | 06/04/2010 | 182 | 21 | 112 | 11 | 112 |
| Média | 09/04/2010 | 15 | 4 | 223 | 33 | 9 |
| Média | 25/04/2011 | 103 | 4 | 48 | 4 | 64 |
| Média | 26/04/2011 | 60 | 8 | 151 | 8 | 37 |
| Média | 15/01/2013 | 47 | 3 | 11 | 5 | 30 |
| Média | 17/01/2013 | 31 | 4 | 60 | 9 | 20 |
| Média | 22/01/2013 | 46 | 6 | 51 | 11 | 29 |
| Média | 23/01/2013 | 0 | 0 | 92 | 16 | 0 |
| Média | 18/03/2013 | 36 | 9 | 65 | 10 | 23 |
| Média | 06/12/2013 | 3 | 1 | 65 | 4 | 2 |
| Média | 11/12/2013 | 106 | 15 | 27 | 4 | 76 |

3.4.2.2. Amostras da Classe (0) – Precipitação Sem Movimento de Massa

Para escolha dos eventos de precipitação da classe (0), para os quais não houve ocorrência de movimento de massa, foi necessário utilizar critérios de seleção, uma vez que todos os eventos de precipitação (Tabela 37), que não geraram movimentos de massa, compõem este conjunto, independentemente de sua magnitude.

Adicionalmente, conforme apresentado no item 3.3, a análise estatística desenvolvida conduziu à observação de que, em termos de magnitude de acumulada diária (mm), os eventos de precipitação relacionados à deflagração de movimentos são provenientes do grupo de valores atípicos/discrepantes (Figura 53).

Desta forma, faz sentido que do grupo de precipitação atípica sejam selecionados os eventos de precipitação da classe (0), resguardando-se, neste caso, uma relação de similaridade entre os intervalos de origem dos eventos representativos da classe (1) com o intervalo de origem dos eventos representativos da classe (0).

Logo, definiu-se que a seleção de eventos de precipitação da classe (0) se daria pela aplicação dos seguintes critérios:

- I. Acumulada diária igual ou maior que 30mm em qualquer um dos 4 (quatro) intervalos e;
- II. Somatório das acumuladas diárias dos 4 (quatro) intervalos igual ou maior que 40% da estimativa de precipitação mensal.

Estes critérios são os mesmos adotados, no item 3.2.2, para depuração de eventos representativos da classe (1). Ainda, neste item há uma melhor fundamentação a seu respeito.

Sendo assim, tanto as amostras/exemplares da classe (0) quanto as amostras/exemplares da classe (1) foram selecionados a partir de um mesmo critério referencial. Como resultado, foram obtidas 172 amostras da classe (0) e 21 amostras da classe (1). No APÊNDICE A, é possível encontrar os dados de entrada, relativos às modulações de precipitação MP01 e MP02, utilizados para construção do modelo classificador.

3.5 Implementação do Modelo

Nesta pesquisa, a aplicação de técnicas de aprendizado de máquina, para predição de ocorrência de movimento de massa, é desenvolvida por meio da adoção de algoritmos para construção dos modelos de classificação, tais algoritmos são Floresta Aleatória (*Random Forest*), Máquina de Vetores Suporte (*Support Vector Machine*) e Perceptron Multicamadas (*Multi-layer Perceptron*), conforme introduzidos no item 2.4.1.

A construção dos modelos de classificação, para predição da classe do evento de precipitação analisado, ocorre tomando-se, como dados de entrada, um conjunto de atributos/fatores relacionados à precipitação. Estes atributos são originados a partir da coleta (item 3.1), pré-processamento (item 3.2) e estruturação dos dados (item 3.4). Os dados de entrada possuem formato tabular, em que as colunas representam os atributos escolhidos e as linhas representam as amostras utilizadas (APÊNDICE A) para treinamento, validação e teste.

Ademais, na Figura 64 é apresentado o processo metodológico utilizado para obtenção da predição de ocorrência ou de não ocorrência de movimento de massa, por meio da classificação do evento de precipitação em classe (0) ou em classe (1).

De modo geral, modelos de aprendizado de máquina são construídos em ambiente de programação. Neste trabalho, o programa utilizado é o *JupyterLab* e a linguagem adotada é *Python*. O *JupyterLab* é um ambiente de programação próprio para criação de roteiros (*scripts*), que objetivam a construção de modelos de aprendizado de máquina, por exemplo.

Para desenvolvimento dos modelos da pesquisa, foram gerados códigos distintos para cada um dos 3 (três) algoritmos, dadas suas particularidades. Ainda, por questões de organização, para cada tipo de dados de entrada (MP01 e MP02) optou-se por um código individualizado. Logo, ao todo foram desenvolvidos 6 (seis) códigos, ou seja, um código para cada modelo.

O estudo de técnicas de aprendizado de máquina conduz à observação de que existe um roteiro básico para construção de modelos, o qual é apresentado em cursos que abordam o tema, tais como ciência de dados ou análise de dados. É recomendado que, para desenvolvimento de um roteiro, tenha-se pelo menos o conhecimento teórico sobre os fundamentos utilizados para construção de modelos de aprendizado de máquina.

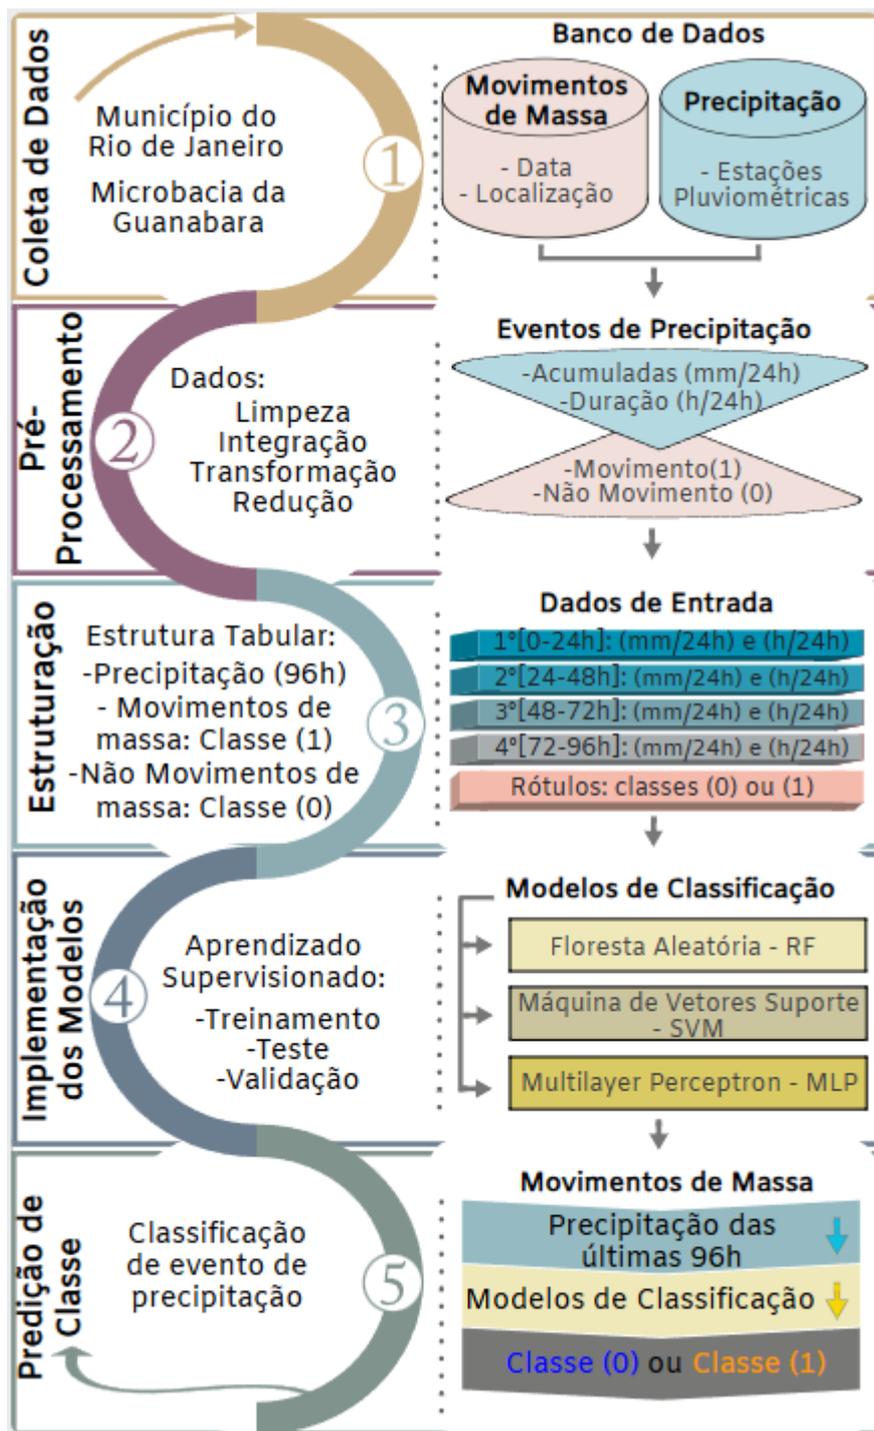


Figura 64 – Procedimento Metodológico

O tema aprendizado de máquina é abrangente e abarca uma série de nuances próprias da área de estudo. Neste trabalho, são abordadas as diretrizes principais que permitem uma compreensão geral do desenvolvimento de um modelo (itens 2.3 e 2.4). Logo, para maiores aprofundamentos a respeito da elaboração de roteiros (*scripts*) é necessário engajamento em cursos que permitirão a expansão do conhecimento na área e desenvolvimento de habilidades práticas de programação.

3.5.1 Segregação de Amostras

A construção de cada um dos 6 (seis) modelos classificadores ocorre de modo iterativo (Figura 16), em que se realizam as fases de treinamento e validação conjuntamente e, posteriormente, a fase de teste do modelo.

À medida que se percorrem os processos iterativos, observações são realizadas e ajustes implementados para que se possa aferir, a partir das métricas adotadas, o desempenho do modelo. Tais ajustes se propõem a, além de conduzir à melhoria de desempenho, afastar o modelo do subajuste (*underfitting*) ou do sobreajuste (*overfitting*). Por este motivo são verificadas as aderências do modelo aos grupos de treinamento, de validação e de teste e, por fim, realizadas comparações.

O objetivo principal é obter o modelo que apresenta melhor desempenho, o qual implica necessariamente que as predições de classe sejam bem-sucedidas na fase de testes.

A matriz de dados de entrada (APÊNDICE A) é composta pelos atributos caracterizadores das MP01 e MP02. Como o modelo é supervisionado, a coluna nomeada por “Rótulos” contém a classe de cada uma das amostras/exemplares utilizadas para treinamento, validação e teste.

O conjunto de dados de entrada das classes (0) e (1), originado conforme indicado no item 3.4.2, é formado por 193 amostras (Tabela 67 e Tabela 68). As amostras da classe (0) representam eventos de precipitação diária em que não houve movimentos de massa e as amostras da classe (1) representam eventos em que houve movimentos de massa.

Originalmente, a classe (0) é composta por 172 amostras e corresponde a aproximadamente 90% das amostras a serem utilizadas pelo algoritmo, enquanto a classe (1) é composta pela fração complementar de 10%. A existência de desbalanceamento de dados em problemas de classificação é comum (AL-Najjar *et al.*, 2021). Por outro lado, o balanceamento das classes é necessário para um melhor desempenho dos modelos classificatórios. Tal equilíbrio pode ser atingido reduzindo-se as amostras da classe majoritária ou incrementando as amostras da classe minoritária. No presente trabalho, face ao número reduzido de amostras (193), optou-se por não reduzir o banco de dados da classe (0), majoritária, e incrementar os da classe (1).

Para ampliação do número de amostras da classe (1) foi utilizada a técnica de sintetização de amostras *SMOTE*. Esta técnica utiliza algoritmo específico para geração de novas amostras e na biblioteca Scikit-Learn (2007), além dela, estão disponibilizados outros algoritmos destinados ao balanceamento de classes. Cabe ressaltar que as amostras geradas artificialmente são utilizadas somente nas fases de treinamento e validação. Na etapa de testes, o banco de dados consiste em amostras originais (item 2.3.2).

Ademais, nas fases de treinamento/validação, o incremento da classe (1) ocorreu com objetivo de igualar a quantidade de amostras de ambas as classes. Desta forma, adotou-se o equilíbrio total entre classes, por meio da geração de amostras sintéticas.

Em termos de segregação das amostras para a fase de treinamento e validação e a fase de testes, devido à pouca quantidade de amostras originais representativas da classe (1), optou-se por destinar 20% do total de amostras ao grupo de teste. Mediante o desequilíbrio de classes, para o grupo de amostras de teste, manteve-se a proporção original de 90% da classe (0) e 10% da Classe (1), conforme Tabela 40.

Tabela 40. Segregação de Amostras de Teste

| Amostras | Treinamento e Validação (80%) | | Testes (20%) | | Total |
|------------|----------------------------------|------------|-----------------|------------|-------|
| | classe (0) | Classe (1) | classe (0) | classe (1) | |
| Quantidade | 137 | 17 | 35 | 4 | 193 |

Sendo assim, restaram 80% de amostras para a fase de treinamento e validação, das quais 89% pertencem à classe (0) e 11% pertencem à classe (1) (Tabela 40). As fases de treinamento e validação foram realizadas por meio do processo de validação cruzada (item 2.3.2), com um conjunto de 5 pastas (k-fold).

O balanceamento de classes, que ocorreu por meio do incremento de amostras da classe (1), foi realizado apenas no grupo de amostras destinado a treinamento e validação (Ramezankhani *et al.*, 2016; Li *et al.*, 2022; Torres *et al.*, 2022), conforme abordado no item 2.3.2. Desta forma, na Tabela 41 é apresentada a quantidade de amostras utilizadas para treinamento e validação do modelo.

Tabela 41. Segregação de Amostras de Treinamento e Validação

| Amostras | Treinamento | | Validação | | Total |
|------------|-------------|------------|------------|------------|-------|
| | 80% | | 20% | | |
| | classe (0) | Classe (1) | classe (0) | classe (1) | |
| Quantidade | 109 | 109 | 28 | 28 | 274 |

3.5.2 Hiperparâmetros

Conforme indicado nos itens 2.3 e 2.4, é necessário escolher valores de hiperparâmetros dos modelos. Sendo assim, para construção da malha de busca foram adotados os intervalos apresentados nas Tabela 42 a

Tabela 44 para os algoritmos Floresta Aleatória, Máquina de Vetores-Suporte e Perceptron Multicamadas, respectivamente.

Tabela 42. Floresta Aleatória – Hiperparâmetros

| | |
|--------------------------|---|
| <i>n_estimators</i> | 100; 200; 300; 400; 500; 600; 700; 800; 900; 1000; 1100; 1200 |
| <i>criterion</i> | gini |
| <i>max_features</i> | None |
| <i>max_depth</i> | 4; 6; 8; 10; 13; 15; 17; 20 |
| <i>min_samples_split</i> | 2; 3; 4; 5; 6; 7; 8; 9; 10 |
| <i>min_samples_leaf</i> | 2; 3; 4; 5; 6; 7; 8; 9; 10 |

Tabela 43. Máquina de Vetores-Suporte – Hiperparâmetros

| | |
|---------------|--|
| <i>C</i> | 0,01; 0,04; 0,08; 0,1; 0,2; 0,3; 0,35; 0,4; 0,45; 0,5; 0,55; 0,6; 0,65; 0,7; 0,75; 0,8; 0,9; 1,0; 1,5; 2,0; 3,0; 4,0; 5,0; 10; 20; 40; 70; 90; 120 |
| <i>kernel</i> | linear; poly; rbf; sigmoid |
| <i>degree</i> | 2; 3; 4 |
| <i>gamma</i> | 0,0001; 0,001; 0,01; 0,04; 0,08; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8; 0,9; 1,0; 2,0; 4,0; 6,0; 8,0; 10,0; 10,5; 11; 11,5; 12; 12,5; 13; 13,5; 14; 14,5; 15; 15,5; 16; 16,5; 17; 17,5; 18; 18,5; 19; 19,5; 20; 100 |

Tabela 44. Perceptron Multicamadas – Hiperparâmetros

| | |
|---------------------------|--|
| <i>hidden_layer_sizes</i> | 2; 4; 8; 12; 16; 18; 20 |
| <i>activation</i> | tanh; logistic; relu |
| <i>solver</i> | lbfgs |
| <i>alpha</i> | 0,01; 0,1; 1; 5; 10 |
| <i>learning_rate</i> | constant; adaptive |
| <i>max_iter</i> | 200; 300; 400; 500; 600; 700; 800; 900; 1000 |

A adoção do método de malha se propõe a observar e analisar os resultados de desempenho do modelo. De modo geral, a busca é realizada utilizando-se uma combinação de intervalos, até que, por meio de processos iterativos, seja encontrada a combinação de hiperparâmetros que resulta nas melhores métricas.

Além dos hiperparâmetros definidos nas Tabela 42 a

Tabela 44, foram adotados os valores pré-definidos (*default*) pela biblioteca Scikit-Learn (2007) para os demais hiperparâmetros de cada um dos três algoritmos (Floresta Aleatória, Máquina de Vetores-Suporte e Perceptron Multicamadas).

3.5.3 Métricas

As métricas adotadas nas fases de validação e testes foram precisão, sensibilidade, acurácia e *AUROC*, conforme introduzido no item 2.4.2. A utilização de conjunto variado de métricas permite estabelecer observações sobre os resultados e tecer interpretações a respeito dos modelos (item 4).

Além das métricas indicadas no subitem anterior, utilizou-se a função log do erro (item 2.4.2) para averiguar a capacidade de previsão do modelo. O erro obtido nas métricas deve ser comparado ao erro referencial máximo, tal como indicado no item 2.4.2. Como foi adotado o completo balanceamento das amostras para treinamento e validação, de forma que 50% das amostras pertencem à classe (1) e os outros 50% pertencem à classe (0), o erro referencial máximo calculado para a fase de validação é de 30%.

Para a fase de testes, existe o desbalanceamento original da amostra, em que aproximadamente 10% das amostras do conjunto pertencem à classe (1). Desta forma, o erro referencial máximo calculado para a fase de teste é de 14%.

4 RESULTADOS

A estruturação dos resultados é realizada em função dos 3 (três) classificadores adotados para desenvolvimento dos modelos, Floresta Aleatória (*Random Forest*), Máquina de Vetores-Suporte (*Support Vector Machine*) e Perceptron Multicamadas (*Multi-layer Perceptron*). Os intervalos de hiperparâmetros (Tabela 42 a

Tabela 44) estabelecem as combinações utilizadas para ajuste dos classificadores. Para cada combinação, estabelece-se um modelo e obtém-se os resultados de suas métricas.

Ainda, para cada classificador foram desenvolvidos modelos com as bases de dados MP01 e MP02. Desta forma, foram calculadas as métricas de validação e teste para cada um dos 6 (seis) modelos desenvolvidos, considerando-se as situações de classes balanceadas e de classes desbalanceadas (APÊNDICE C).

Para fins didáticos, no item 4.1.1 foi detalhada a análise das métricas do modelo Floresta Aleatória, com a modulação temporal MP01, para classes desbalanceadas e balanceadas. Para os demais modelos, as análises com classes desbalanceadas está apresentada no APÊNDICE C, visto que, pela experiência, os resultados das métricas com classes desbalanceadas não representam o desempenho do modelo e se propõem principalmente ao estabelecimento de uma referência inicial.

4.1 Modelos Floresta Aleatória (*Random Forest - RF*)

Para as MP01 e MP02 foram realizadas as etapas de treinamento, validação e teste dos modelos utilizando combinações dos hiperparâmetros apresentados na Tabela 42.

4.1.1 Modulação Temporal – MP01

Com os resultados da fase de treinamento e validação, realizou-se a pré-seleção dos modelos que apresentaram os menores erros de validação, os quais pertencem ao intervalo 0,3 a 0,39 e, também, cujos valores de *AUROC* são maiores ou iguais a 0,7 (item 2.4.2). Posteriormente, os modelos pré-selecionados foram submetidos à fase de teste. A partir dos resultados de teste, foram considerados os modelos que apresentaram os menores erros, e cujos valores de *AUROC* são maiores ou iguais a 0,7.

Na Tabela 45, estão elencados os hiperparâmetros dos modelos Floresta Aleatória - MP01 que resultaram nas 8 (oito) melhores combinações de erro e de *AUROC*, nas etapas de validação e de teste, para a situação de classes balanceadas. A Tabela 45 permite a verificação de que os modelos apresentam:

- Erros de treinamento, que variam de 0,178 a 0,218, inferiores aos erros de validação e de teste e, também, inferiores aos limites referenciais de erro (item 3.5.3), que é de 0,3 para treinamento;
- Erros de validação entre 0,308 a 0,322 e erros de teste entre 0,316 a 0,318. No quesito de erros, os resultados de teste se aproximam dos resultados de validação. Embora ambos estejam próximos ou ultrapassem os limites referenciais de erro (item 3.5.3), que é de 0,3 para validação e de 0,14 para teste;
- As *AUROC* de treinamento variam de 0,983 a 0,969, as *AUROC* de validação variam de 0,883 a 0,876 e as *AUROC* de teste variam de 0,807 a 0,750. Neste caso, apenas os modelos 1 e 2 (Tabela 45) possuem *AUROC* de teste que se aproximam da *AUROC* de validação. Por outro lado, para todos os modelos (Tabela 45) as *AUROC* de treinamento são superiores às de validação;
- Valores de limiar otimizado, para o conjunto de teste, que estão entre 0,107 e 0,125. Este é um indicador de que os modelos, em relação ao conjunto de amostras com as quais nunca tiveram contato, não realizam a distribuição de classes no intervalo de 0 a 1. Neste caso, a distribuição está ocorrendo no intervalo de 0 a 0,2;
- Métricas acurácia, precisão e sensibilidade de teste iguais a 0,0 (zero), pois o limiar padrão em 0,5 impõe que todas as amostras, as quais estão distribuídas no intervalo de 0 a 0,2, sejam classificadas como classe (0).

Considera-se que o modelo 1 (Tabela 45), que foi obtido a partir do balanceamento de classes, apresenta o melhor desempenho com menor erro de validação em combinação com um dos menores erros de teste e, também, com uma das maiores *AUROC* de validação, da qual a *AUROC* de teste se aproxima.

Adicionalmente, as métricas de erro de validação e de teste indicam que o modelo, mesmo após variações nos valores de hiperparâmetros, não atingiu o desempenho desejado, principalmente quando se observa que os menores erros de

validação estão próximos ou acima de 0,3. De qualquer forma, no item 4.1.1.2 é realizada uma análise detalhada deste modelo.

Quanto à situação de classes desbalanceadas, a apresentação dos resultados no item 4.1.1.1 objetiva fornecer uma referência do comportamento do modelo quando o desbalanceamento entre amostras da classe (0) e classe (1) é acentuado e, desta forma, para fins didáticos, caracterizar a necessidade de balancear as amostras no pré-processamento.

Tabela 45. Floresta Aleatória – MP01: Hiperparâmetros, Métricas e Limiares

| Modelo | Hiperparâmetros | | | | | | Métricas de Treinamento | | | | | |
|--------|------------------|-----------|------------------|---------------|--------------------------|-------------------------|-------------------------|-------|----------|---------------|-------|------------------|
| | n_ estimators | criterion | max_ features | max_ depth | min_ samples split | min_ samples leaf | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão |
| 1 | 1100 | gini | None | 4 | 8 | 2 | 0,943 | 0,983 | 0,691 | 0,929 | 0,178 | 0,500 |
| 2 | 1100 | gini | None | 4 | 10 | 2 | 0,941 | 0,979 | 0,687 | 0,914 | 0,186 | 0,500 |
| 3 | 1100 | gini | None | 4 | 2 | 4 | 0,940 | 0,978 | 0,681 | 0,914 | 0,192 | 0,500 |
| 4 | 1100 | gini | None | 4 | 4 | 4 | 0,940 | 0,978 | 0,681 | 0,914 | 0,192 | 0,500 |
| 5 | 1000 | gini | None | 4 | 6 | 2 | 0,943 | 0,987 | 0,691 | 0,929 | 0,171 | 0,500 |
| 6 | 1200 | gini | None | 4 | 2 | 4 | 0,940 | 0,978 | 0,681 | 0,914 | 0,192 | 0,500 |
| 7 | 1200 | gini | None | 4 | 4 | 4 | 0,940 | 0,978 | 0,681 | 0,914 | 0,192 | 0,500 |
| 8 | 1100 | gini | None | 4 | 2 | 6 | 0,924 | 0,969 | 0,622 | 0,871 | 0,218 | 0,500 |

(continua)

| Modelo | Métricas de Validação | | | | | | Métricas de Teste | | | | | Limiar Otimizado |
|--------|-----------------------|-------|----------|---------------|-------|------------------|-------------------|-------|----------|---------------|-------|---------------------|
| | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão | Acurácia | AUROC | Precisão | Sensibilidade | Erro | |
| 1 | 0,865 | 0,879 | 0,413 | 0,400 | 0,308 | 0,500 | 0,897 | 0,807 | 0,000 | 0,000 | 0,316 | 0,125 |
| 2 | 0,865 | 0,879 | 0,413 | 0,400 | 0,310 | 0,500 | 0,897 | 0,800 | 0,000 | 0,000 | 0,316 | 0,125 |
| 3 | 0,865 | 0,883 | 0,413 | 0,400 | 0,311 | 0,500 | 0,897 | 0,750 | 0,000 | 0,000 | 0,316 | 0,125 |
| 4 | 0,865 | 0,879 | 0,413 | 0,400 | 0,310 | 0,500 | 0,897 | 0,757 | 0,000 | 0,000 | 0,316 | 0,125 |
| 5 | 0,871 | 0,876 | 0,440 | 0,467 | 0,322 | 0,500 | 0,897 | 0,771 | 0,000 | 0,000 | 0,319 | 0,111 |
| 6 | 0,871 | 0,876 | 0,440 | 0,467 | 0,322 | 0,500 | 0,897 | 0,771 | 0,000 | 0,000 | 0,319 | 0,111 |
| 7 | 0,871 | 0,876 | 0,440 | 0,467 | 0,322 | 0,500 | 0,897 | 0,771 | 0,000 | 0,000 | 0,319 | 0,111 |
| 8 | 0,858 | 0,876 | 0,433 | 0,400 | 0,319 | 0,500 | 0,897 | 0,750 | 0,000 | 0,000 | 0,319 | 0,107 |

(conclusão)

4.1.1.1. Classes Desbalanceadas

Para fins de comparação entre os resultados de classes desbalanceadas e balanceadas, foram utilizados os hiperparâmetros do modelo 1 da Tabela 45. Desta forma, na Tabela 46, estão compilados os resultados das métricas de desempenho de treinamento, validação e de teste, para classes desbalanceadas, referente ao limiar padrão em 0,5 adotado pela biblioteca Scikit-Learn (2007).

Tabela 46. Floresta Aleatória – MP01: Classes Desbalanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,90 | 0,90 | 0,90 |
| AUROC | 0,99 | 0,82 | 0,40 |
| Precisão | 1,00 | 0,20 | 0,0 |
| Sensibilidade | 0,16 | 0,07 | 0,0 |
| Erro | 0,19 | 0,25 | 0,34 |

I. Quanto ao Treinamento e à Validação

A apresentação das métricas de treinamento objetiva explicitar a resposta de aderência do algoritmo em relação aos dados utilizados para treinamento. Como se pode observar na Tabela 46, as métricas de treinamento acurácia, AUROC e precisão podem ser consideradas excelentes, pois estão próximas ou são iguais ao valor máximo, que é 1,0 (um), com exceção da sensibilidade, a qual é afetada pelo fato de que há apenas 10% de amostras da classe (1).

De modo geral, a interpretação da métrica de treinamento é que o algoritmo é capaz de classificar corretamente os dados de treinamento. Entretanto pode falhar em estabelecer predições de classe, tal como fica explicitado ao se verificar as diferenças entre as métricas precisão (Equação 7) e sensibilidade (Equação 8) de treinamento com as de validação.

Na Tabela 46, identifica-se que as métricas acurácia de treinamento, validação e teste das classes desbalanceadas, convergem para o valor 1,0 (um). Neste caso, deve-se atentar para o fato de que o modelo se torna tendencioso em classificar a classe (0), que é majoritária, fato que resulta em um valor de acurácia próximo ou igual a 1,0.

Sendo assim, caracteriza-se a necessidade de utilização de outras métricas, além da acurácia, tal como *AUROC* e erro, para uma melhor análise da capacidade de generalização do modelo. Os resultados de *AUROC* do treinamento e da validação estão acima da referência de 0,7 (item 2.4.2). Entretanto, o erro limite de referência, para um conjunto cuja classe (1) é representada por 10% de amostras, é 0,14. Sendo assim, tanto no treinamento quanto na validação este valor limite foi extrapolado.

II. Quanto ao Teste

Em termos de classes desbalanceadas (Tabela 46), as métricas das amostras de teste, principalmente *AUROC* e erro, indicam que o modelo, para amostras com as quais nunca teve contato, não é capaz de realizar boas previsões em relação a classe (1). Logo, ele não consegue prever a ocorrência de movimentos de massa.

Ainda, a convergência da métrica acurácia na validação e no teste para classes desbalanceadas corrobora com o fato de que o modelo é capaz de classificar principalmente eventos pertencentes à classe (0). A maioria das amostras dos grupos de treinamento e de validação pertencem à classe (0). Desta forma, no treinamento, o modelo possui maior contato com amostras de rótulo (0) e desenvolve forte tendência a classificar eventos em classe (0). Como na validação e no teste a maior parte das amostras também pertencem à classe (0), ele é bem-sucedido nas previsões desta classe e obtém acurácia de 90%.

4.1.1.2. Classes Balanceadas

Com classes desbalanceadas não foi possível obter modelo capaz de prever a ocorrência de movimento de massa, que é caracterizado pela classe (1). Desta forma, para classes balanceadas e considerando o limiar padrão em 0,5, tem-se, na Tabela 47, os resultados das métricas de desempenho do modelo 1 (Tabela 45) para os conjuntos de treinamento, validação e de teste.

Tabela 47. Floresta Aleatória – MP01: Classes Balanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,94 | 0,87 | 0,90 |
| <i>AUROC</i> | 0,98 | 0,88 | 0,81 |
| Precisão | 0,69 | 0,41 | 0,0 |
| Sensibilidade | 0,93 | 0,40 | 0,0 |
| Erro | 0,18 | 0,31 | 0,32 |

I. Quanto ao Treinamento e à Validação

As métricas de treinamento e validação, para classes balanceadas, apresentaram evolução da sensibilidade em relação às das classes desbalanceadas (item 4.1.1.1). Este é um indicador de que o modelo, quando treinado com classes balanceadas, classifica corretamente mais amostras da classe (1). Entretanto, como o valor de precisão continua baixo, entende-se que o número de falsos positivos é representativo.

Ainda, comparando-se os resultados de classes desbalanceadas com os de balanceadas, a métrica erro de validação aumentou e se aproximou do valor limite de referência 0,3, possivelmente pelo fato de que o modelo ainda apresenta dificuldade em classificar corretamente as amostras da classe (1) e/ou apresenta distribuição probabilística apenas em parte do intervalo de 0 a 1,0.

Em relação à comparação das métricas de treinamento e validação, para classes balanceadas (Tabela 47), observa-se que acurácia, *AUROC*, precisão e sensibilidade de validação são inferiores às de treinamento e o erro de validação, além de ser maior do que o erro de treinamento, é superior ao referencial limite de 0,3. Entende-se que o erro de validação (0,31), tomado em conjunto com o valor de *AUROC* (0,88), é indicativo de que a distribuição probabilística das amostras de validação pode não estar bem distribuída no intervalo 0 a 1, de modo que o limiar padrão de 0,5 impõe baixos valores de precisão (0,4) e de sensibilidade (0,4).

De qualquer forma, no que tange às diferenças entre erro e *AUROC* de treinamento e validação, é esperado que, em função da capacidade de generalização do modelo, o erro de validação seja maior do que o erro de treinamento. Entretanto, quando o erro ultrapassa o valor limite de referência, compreende-se que o modelo carece de melhoria. Desta forma, considerando-se que a modificação de hiperparâmetros não resulta mais em melhoria de desempenho, conclui-se que as limitações são principalmente impostas pela quantidade de amostras e o acentuado desbalanceamento original de classes (Tabela 40 e Tabela 41).

II. Quanto ao Teste

A *AUROC* de teste das classes balanceadas se aproxima da *AUROC* de validação e ambas são maiores do que 0,7 (Tabela 47). A comparação entre as *AUROC*, conduz à interpretação de que, com o balanceamento de classes, o modelo apresentou melhor desempenho em classificar amostras com as quais nunca teve contato.

Nesta situação, ambas *AUROC* sinalizam que o modelo classificador está generalizando melhor. No caso do teste, *AUROC* igual a 0,81 significa que o modelo, na maioria das vezes (81%), classifica corretamente um caso positivo, atribuindo a ele uma probabilidade maior de pertencer à classe (1) do que de pertencer à classe (0).

Os modelos, de modo geral, além da predição de classe, podem responder em termos de probabilidade de um evento pertencer a uma ou a outra classe. A curva *ROC* é originada a partir da distribuição probabilística das amostras em combinação com os possíveis limiares (Figura 28 e Figura 29). A matriz de confusão é oriunda de determinado limiar admitido (Figura 30).

Na Figura 65, para fins didáticos e para o modelo Floresta Aleatória – MP01, são apresentados a distribuição probabilística, a predição de classe, a classe real das amostras e a projeção conjunta dos limiares padrão e otimizado do conjunto de dados de teste. Além disto, na Figura 65, também é possível observar os falsos-positivos (FP), falsos-negativos (FN), verdadeiros-positivos (VP) e verdadeiros-negativos (VN), que deu origem à matriz de confusão referente ao limiar otimizado (Figura 67).

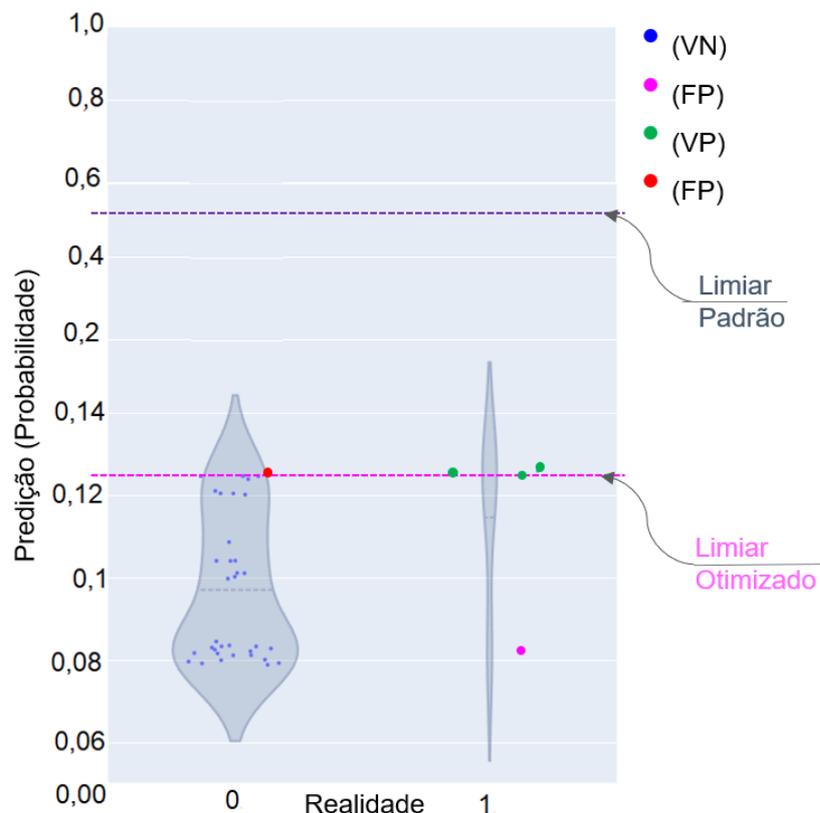


Figura 65 – Floresta Aleatória (MP01): Distribuição Probabilística - Limiar Padrão e Limiar Otimizado - Teste

No caso da sensibilidade e da precisão apresentadas na Tabela 47, o limiar utilizado é 0,5, este valor de limiar é adotado como padrão pela biblioteca Scikit-Learn (2007), tal como representado na Figura 65.

Como resultado da adoção do limiar padrão, tem-se, na Figura 66, a matriz de confusão referente ao limiar padrão da qual são originadas precisão (0%), sensibilidade (0%) e acurácia (90%) apresentadas na Tabela 47.

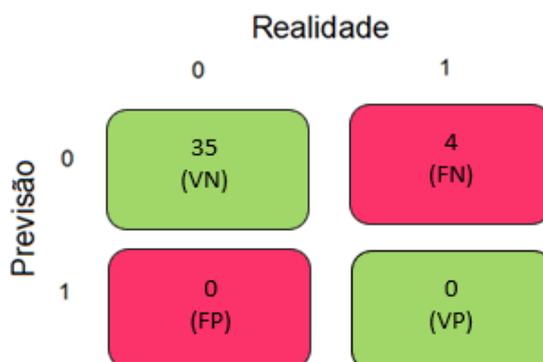


Figura 66 – Floresta Aleatória (MP01): Matriz de Confusão - Limiar Padrão - Teste

Desta forma, embora precisão e sensibilidade de teste da classe balanceada tenha resultado no valor 0,0 (zero), a *AUROC* igual a 81% sinaliza a existência de um limiar otimizado (item 2.4.2.1) em que se pode obter uma melhor combinação entre precisão e sensibilidade. Na Tabela 48 são apresentados os valores de precisão e sensibilidade de teste obtidos para o limiar otimizado do modelo 1 (Tabela 45) e na Figura 67 é apresentada a matriz de confusão da qual são originadas precisão (75%), sensibilidade (75%) e acurácia (95%).

Tabela 48. Floresta Aleatória – MP01: Classes Balanceadas e Limiar Otimizado

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,94 | 0,87 | 0,95 |
| <i>AUROC</i> | 0,98 | 0,88 | 0,81 |
| Precisão | 0,69 | 0,41 | 0,75 |
| Sensibilidade | 0,93 | 0,40 | 0,75 |
| Erro | 0,18 | 0,31 | 0,32 |

Na Figura 67, tem-se a matriz de confusão do limiar otimizado igual a 0,13. Desta forma é possível comparar as Figura 66 e Figura 67 e observar que o ajuste do limiar pode resultar em variação da precisão, sensibilidade e da acurácia, tal como indicado numericamente na coluna “Teste” da Tabela 48.

| | | Realidade | |
|----------|---|------------|-----------|
| | | 0 | 1 |
| Previsão | 0 | 34 (VN) | 1 (FN) |
| | 1 | 1 (FP) | 3 (VP) |

Figura 67 – Floresta Aleatória (MP01): Matriz de Confusão - Limiar Otimizado - Teste

De qualquer forma, embora as *AUROC* de validação e de teste (Tabela 47) se aproximem e este seja um fator indicativo de que o modelo apresenta maior capacidade de realizar classificações corretamente quando balanceado, as métricas de erro de validação e de teste estão próximas ao valor limite de referência 0,3. Sendo assim, entende-se que o modelo apresenta dificuldade em reconhecer a distribuição das amostras, como pode ser verificado por meio do valor 0,13 de limiar otimizado, o qual impacta na correta classificação de amostras da classe (1). De modo geral, relaciona-se esta limitação de desempenho do modelo à quantidade de amostras para treinamento, validação e teste, fato agravado pelo desbalanceamento de classe, cuja quantidade de amostras da classe (1) é 10% do total de amostras (Tabela 40 e Tabela 41).

4.1.2 Modulação Temporal – MP02

A partir dos resultados da fase de treinamento e validação do modelo Floresta Aleatória - MP02, realizou-se a pré-seleção dos modelos que apresentaram os menores erros de validação, os quais pertencem ao intervalo 0,4 a 0,49 e, também, cujos valores de *AUROC* são maiores ou iguais a 0,7 (item 2.4.2). Posteriormente, os modelos pré-selecionados foram submetidos à fase de teste. A partir dos resultados de teste, foram considerados os modelos que apresentaram os menores erros, e cujos valores de *AUROC* são maiores ou iguais a 0,7.

Na Tabela 49, estão elencados os hiperparâmetros dos modelos Floresta Aleatória - MP02 que resultaram nas 8 (oito) melhores combinações de erro e de *AUROC*, nas etapas de validação e de teste, para a situação de classes balanceadas. A Tabela 49 permite a verificação de que os modelos apresentam:

- Erros de treinamento, que variam de 0,246 a 0,323, são inferiores aos erros de validação e de teste, mas, em sua maioria, superiores aos limites referenciais de erro (item 3.5.3), que é de 0,3 para treinamento;
- Erros de validação entre 0,427 a 0,436 e erros de teste entre 0,319 a 0,331. No quesito de erros, os resultados de teste são inferiores do que os resultados de validação. Entretanto, ambos ultrapassam os limites referenciais de erro (item 3.5.3), que é de 0,3 para validação e de 0,14 para teste;
- As *AUROC* de treinamento variam de 0,926 a 0,964, as *AUROC* de validação variam de 0,752 a 0,783 e as *AUROC* de teste variam de 0,732 a 0,739. Neste caso, para todos os modelos (Tabela 49) as *AUROC* de treinamento são superiores às de validação e de teste;
- Valores de limiar otimizado, para o conjunto de teste, que estão entre 0,280 e 0,302. Este é um indicador de que os modelos, em relação ao conjunto de amostras com as quais nunca tiveram contato, não realizam a distribuição de classes no intervalo de 0 a 1. Neste caso, a distribuição está ocorrendo no intervalo de 0 a 0,3;
- Métricas acurácia, precisão e sensibilidade de teste iguais a 0,0 (zero), pois o limiar padrão em 0,5 impõe que todas as amostras, as quais estão distribuídas no intervalo de 0 a 0,3, sejam classificadas como classe (0).

Considera-se que o modelo 1 (Tabela 49), que foi obtido a partir do balanceamento de classes, apresenta o melhor desempenho com menor erro de validação em combinação com um dos menores erros de teste, embora sua *AUROC* de validação não seja uma das maiores. Adicionalmente, as métricas de erro de validação e de teste indicam que o modelo, mesmo após variações nos valores de hiperparâmetros, não atingiu o desempenho ótimo, que é o que almeja, principalmente quando se observa que os menores erros de validação estão acima de 0,4. De qualquer forma, no item 4.1.2.1 é realizada uma análise detalhada deste modelo.

Quanto à situação de classes desbalanceadas, a apresentação dos resultados no item (a) do APÊNDICE C objetiva fornecer uma referência do comportamento do modelo quando o desbalanceamento entre amostras da classe (0) e classe (1) é acentuado e, desta forma, para fins didáticos, caracterizar a necessidade de balancear as amostras no pré-processamento.

Tabela 49. Floresta Aleatória – MP02: Hiperparâmetros, Métricas e Limiares

| Modelo | Hiperparâmetros | | | | | | Métricas de Treinamento | | | | | |
|--------|------------------|-----------|------------------|---------------|--------------------------|-------------------------|-------------------------|-------|----------|---------------|-------|------------------|
| | n_ estimators | criterion | max_ features | max_ depth | min_ samples split | min_ samples leaf | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão |
| 1 | 700 | gini | None | 6 | 2 | 8 | 0,876 | 0,942 | 0,475 | 0,786 | 0,288 | 0,500 |
| 2 | 700 | gini | None | 4 | 2 | 8 | 0,867 | 0,937 | 0,452 | 0,771 | 0,303 | 0,500 |
| 3 | 600 | gini | None | 4 | 2 | 8 | 0,863 | 0,936 | 0,444 | 0,757 | 0,303 | 0,500 |
| 4 | 700 | gini | None | 8 | 2 | 6 | 0,911 | 0,964 | 0,575 | 0,829 | 0,246 | 0,500 |
| 5 | 600 | gini | None | 6 | 2 | 10 | 0,857 | 0,929 | 0,426 | 0,729 | 0,316 | 0,500 |
| 6 | 700 | gini | None | 6 | 2 | 10 | 0,855 | 0,929 | 0,422 | 0,729 | 0,316 | 0,500 |
| 7 | 600 | gini | None | 4 | 2 | 10 | 0,852 | 0,927 | 0,415 | 0,729 | 0,323 | 0,500 |
| 8 | 700 | gini | None | 4 | 2 | 10 | 0,850 | 0,926 | 0,411 | 0,714 | 0,323 | 0,500 |

(continua)

| Modelo | Métricas de Validação | | | | | | Métricas de Teste | | | | | Limiar Otimizado |
|--------|-----------------------|-------|----------|---------------|-------|------------------|-------------------|-------|----------|---------------|-------|---------------------|
| | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão | Acurácia | AUROC | Precisão | Sensibilidade | Erro | |
| 1 | 0,813 | 0,762 | 0,294 | 0,467 | 0,427 | 0,500 | 0,897 | 0,739 | 0,000 | 0,000 | 0,321 | 0,301 |
| 2 | 0,800 | 0,767 | 0,299 | 0,533 | 0,429 | 0,500 | 0,897 | 0,739 | 0,000 | 0,000 | 0,322 | 0,302 |
| 3 | 0,800 | 0,767 | 0,299 | 0,533 | 0,430 | 0,500 | 0,897 | 0,739 | 0,000 | 0,000 | 0,322 | 0,298 |
| 4 | 0,800 | 0,752 | 0,222 | 0,400 | 0,434 | 0,500 | 0,897 | 0,739 | 0,000 | 0,000 | 0,331 | 0,323 |
| 5 | 0,800 | 0,783 | 0,299 | 0,533 | 0,435 | 0,500 | 0,897 | 0,732 | 0,000 | 0,000 | 0,320 | 0,282 |
| 6 | 0,794 | 0,783 | 0,294 | 0,533 | 0,435 | 0,500 | 0,897 | 0,736 | 0,000 | 0,000 | 0,319 | 0,282 |
| 7 | 0,806 | 0,781 | 0,307 | 0,533 | 0,436 | 0,500 | 0,897 | 0,732 | 0,000 | 0,000 | 0,320 | 0,280 |
| 8 | 0,800 | 0,783 | 0,299 | 0,533 | 0,436 | 0,500 | 0,897 | 0,736 | 0,000 | 0,000 | 0,320 | 0,281 |

(conclusão)

4.1.2.1. Classes Balanceadas

Com classes desbalanceadas não foi possível obter modelo capaz de prever a ocorrência de movimento de massa, que é caracterizado pela classe (1). Desta forma, para classes balanceadas e considerando o limiar padrão em 0,5, tem-se, na Tabela 50, os resultados das métricas de desempenho do modelo 1 (Tabela 49) para os conjuntos de treinamento, validação e de teste.

Tabela 50. Floresta Aleatória – MP02: Classes Balanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,88 | 0,81 | 0,90 |
| <i>AUROC</i> | 0,94 | 0,76 | 0,74 |
| Precisão | 0,48 | 0,29 | 0,0 |
| Sensibilidade | 0,79 | 0,47 | 0,0 |
| Erro | 0,29 | 0,43 | 0,32 |

I. Quanto ao Treinamento e à Validação

As métricas de treinamento e validação, para classes balanceadas, apresentaram evolução da sensibilidade em relação às das classes desbalanceadas (item (a) - APÊNDICE C). Este é um indicador de que o modelo, quando treinado com classes balanceadas, classifica corretamente mais amostras da classe (1). Entretanto, como o valor de precisão continua baixo, entende-se que o número de falsos positivos é representativo.

Ainda, comparando-se os resultados de classes desbalanceadas com os de balanceadas, a métrica erro de validação aumentou e ultrapassou o valor limite de referência 0,3, possivelmente pelo fato de que o modelo ainda apresenta dificuldade em classificar corretamente as amostras da classe (1) e/ou apresenta distribuição probabilística apenas em parte do intervalo de 0 a 1,0.

Em relação à comparação das métricas de treinamento e validação, para classes balanceadas (Tabela 50), observa-se que acurácia, *AUROC*, precisão e sensibilidade de validação são inferiores às de treinamento e o erro de validação, além de ser maior do que o erro de treinamento, é superior ao referencial limite de 0,3. Entende-se que o erro de validação (0,43), tomado em conjunto com o valor de *AUROC* (0,76), é indicativo de que a distribuição probabilística das amostras de validação pode não estar bem distribuída no intervalo 0 a 1, de modo que o limiar padrão de 0,5 impõe baixos valores de precisão (0,29) e de sensibilidade (0,47).

De qualquer forma, no que tange às diferenças entre erro e *AUROC* de treinamento e validação, é esperado que, em função da capacidade de generalização do modelo, o erro de validação seja maior do que o erro de treinamento. Entretanto, quando o erro ultrapassa o valor limite de referência, compreende-se que o modelo carece de melhoria. Desta forma, considerando-se que a modificação de hiperparâmetros não resulta mais em melhoria de desempenho, conclui-se que as limitações são principalmente impostas pela quantidade de amostras e o acentuado desbalanceamento original de classes (Tabela 40 e Tabela 41).

II. Quanto ao Teste

A *AUROC* de teste das classes balanceadas se aproxima da *AUROC* de validação e ambas são maiores do que 0,7 (item 2.4.2). A comparação entre as *AUROC*, conduz à interpretação de que, com o balanceamento de classes, o modelo apresentou melhor desempenho em classificar amostras com as quais nunca teve contato. Nesta situação, ambas *AUROC* sinalizam que o modelo classificador está generalizando melhor. No caso do teste, *AUROC* igual a 0,74 significa que o modelo, na maioria das vezes (74%), classifica corretamente um caso positivo, atribuindo a ele uma probabilidade maior de pertencer à classe (1) do que de pertencer à classe (0).

Os modelos, de modo geral, além da predição de classe, podem responder em termos de probabilidade de um evento pertencer a uma ou a outra classe. A curva *ROC* é originada a partir da distribuição probabilística das amostras em combinação com os possíveis limiares (Figura 28 e Figura 29). A matriz de confusão é oriunda de determinado limiar admitido (Figura 30). No caso da sensibilidade e da precisão apresentadas na Tabela 50, o limiar utilizado é 0,5, este valor de limiar é adotado como padrão pela biblioteca Scikit-Learn (2007). Na Figura 68, é apresentada a matriz de confusão referente ao limiar padrão da qual são originadas precisão (0%), sensibilidade (0%) e acurácia (90%) apresentadas na Tabela 50.

| | | Realidade | |
|----------|---|------------|-----------|
| | | 0 | 1 |
| Previsão | 0 | 35 (VN) | 4 (FN) |
| | 1 | 0 (FP) | 0 (VP) |

Figura 68 – Floresta Aleatória (MP02): Matriz de Confusão - Limiar Padrão - Teste

Desta forma, embora precisão e sensibilidade de teste da classe balanceada tenha resultado no valor 0,0 (zero), a *AUROC* igual a 74% sinaliza a existência de um limiar otimizado (item 2.4.2.1) em que se pode obter uma melhor combinação entre precisão e sensibilidade. Na Tabela 51 são apresentados os valores de precisão e sensibilidade de teste obtidos para o limiar otimizado do modelo 1 (Tabela 49) e na Figura 69 é apresentada a matriz de confusão da qual são originadas precisão (20%), sensibilidade (75%) e acurácia (67%).

Tabela 51. Floresta Aleatória – MP02: Classes Balanceadas e Limiar Otimizado

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,88 | 0,81 | 0,67 |
| <i>AUROC</i> | 0,94 | 0,76 | 0,74 |
| Precisão | 0,48 | 0,29 | 0,20 |
| Sensibilidade | 0,79 | 0,47 | 0,75 |
| Erro | 0,29 | 0,43 | 0,32 |

Na Figura 69, tem-se a matriz de confusão do limiar otimizado igual a 0,32. Desta forma é possível comparar as Figura 68 e Figura 69 e observar que o ajuste do limiar pode resultar em variação da precisão, sensibilidade e da acurácia, tal como indicado numericamente na coluna “Teste” da Tabela 51.

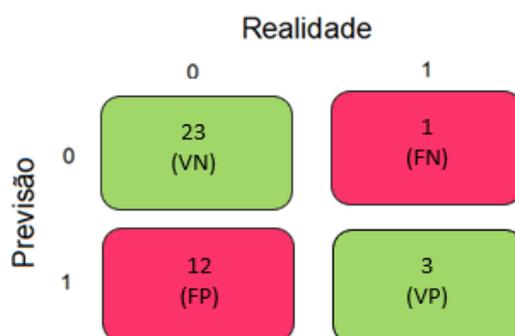


Figura 69 – Floresta Aleatória (MP02): Matriz de Confusão - Limiar Otimizado - Teste

De qualquer forma, embora as *AUROC* de validação e de teste (Tabela 50) se aproximem e este seja um fator indicativo de que o modelo apresenta maior capacidade de realizar classificações corretamente quando balanceado, as métricas de erro de validação e de teste ultrapassaram o valor limite de referência 0,3. Sendo assim, entende-se que o modelo apresenta dificuldades em reconhecer a distribuição das amostras, como pode ser verificado por meio do valor 0,32 de limiar otimizado, o qual impacta na correta classificação de amostras da classe (1).

De modo geral, relaciona-se esta limitação de desempenho do modelo à quantidade de amostras para treinamento, validação e teste, fato agravado pelo desbalanceamento de classe, cuja quantidade de amostras da classe (1) é 10% do total de amostras (Tabela 40 e Tabela 41).

4.2 Modelos Máquina de Vetores-Suporte (*Support Vector Machine - SVM*)

Para as MP01 e MP02 foram realizadas as etapas de treinamento, validação e teste dos modelos utilizando combinações dos hiperparâmetros apresentados na Tabela 43.

4.2.1 Modulação Temporal – MP01

Com os resultados da fase de treinamento e validação, realizou-se a pré-seleção dos modelos que apresentaram os menores erros de validação, os quais pertencem ao intervalo 0,3 a 0,39 e, também, cujos valores de *AUROC* são maiores ou iguais a 0,7 (item 2.4.2). Posteriormente, os modelos pré-selecionados foram submetidos à fase de teste. A partir dos resultados de teste, foram considerados os modelos que apresentaram os menores erros, e cujos valores de *AUROC* são maiores ou iguais a 0,7.

Na Tabela 52, estão elencados os hiperparâmetros dos modelos Máquina de Vetores-Suporte - MP01 que resultaram nas 8 (oito) melhores combinações de erro e de *AUROC*, nas etapas de validação e de teste, para a situação de classes balanceadas. A Tabela 52 permite a verificação de que os modelos apresentam:

- Erros de treinamento, que variam de 0,119 a 0,139, são inferiores aos erros de validação e de teste e, também, inferiores aos limites referenciais de erro (item 3.5.3), que é de 0,3 para treinamento;
- Erros de validação entre 0,364 a 0,369 e erros de teste entre 0,327 a 0,350. No quesito de erros, os resultados de teste se aproximam dos resultados de validação. Embora ambos estejam próximos ou ultrapassem os limites referenciais de erro (item 3.5.3), que é de 0,3 para validação e de 0,14 para teste;

- As *AUROC* de treinamento variam de 0,977 a 0,993, as *AUROC* de validação variam de 0,786 a 0,798 e as *AUROC* de teste variam de 0,750 a 0,779. Para todos os modelos (Tabela 52), as *AUROC* de treinamento são superiores às de validação e às de teste e, também, as *AUROC* de teste se aproximam das de validação;
- Valores de limiar otimizado, para o conjunto de teste, que estão entre 0,117 e 0,182. Este é um indicador de que os modelos, em relação ao conjunto de amostras com as quais nunca tiveram contato, não realizam a distribuição de classes no intervalo de 0 a 1. Neste caso, a distribuição está ocorrendo no intervalo de 0 a 0,2;
- Métricas acurácia, precisão e sensibilidade de teste iguais a 0,0 (zero), pois o limiar padrão em 0,5 impõe que todas as amostras, as quais estão distribuídas no intervalo de 0 a 0,2, sejam classificadas como classe (0).

Considera-se que o modelo 1 (Tabela 52), que foi obtido a partir do balanceamento de classes, apresenta o melhor desempenho com menor erro de validação e, também, com a maior *AUROC* de validação. Adicionalmente, as métricas de erro de validação e de teste indicam que o modelo, mesmo após variações nos valores de hiperparâmetros, não atingiu o desempenho desejado, principalmente quando se observa que os menores erros de validação estão próximos ou acima de 0,3. De qualquer forma, no item 4.2.1.1 é realizada uma análise detalhada deste modelo.

Quanto à situação de classes desbalanceadas, a apresentação dos resultados no item (b) do APÊNDICE C objetiva fornecer uma referência do comportamento do modelo quando o desbalanceamento entre amostras da classe (0) e classe (1) é acentuado e, desta forma, para fins didáticos, caracterizar a necessidade de balancear as amostras no pré-processamento.

Tabela 52. Máquina de Vetores-Suporte – MP01: Hiperparâmetros, Métricas e Limiares

| Modelo | Hiperparâmetros | | | | Métricas de Treinamento | | | | | |
|--------|-----------------|--------|-------|--------|-------------------------|-------|----------|---------------|-------|---------------|
| | C | degree | gamma | kernel | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão |
| 1 | 0,35 | - | 13 | rbf | 0,915 | 0,987 | 0,580 | 0,986 | 0,154 | 0,500 |
| 2 | 0,35 | - | 13,5 | rbf | 0,922 | 0,988 | 0,601 | 0,986 | 0,150 | 0,500 |
| 3 | 0,35 | - | 14 | rbf | 0,928 | 0,989 | 0,623 | 0,986 | 0,146 | 0,500 |
| 4 | 0,4 | - | 14,5 | rbf | 0,941 | 0,993 | 0,670 | 0,986 | 0,122 | 0,500 |
| 5 | 0,3 | - | 11,5 | rbf | 0,894 | 0,977 | 0,523 | 0,986 | 0,192 | 0,500 |
| 6 | 0,35 | - | 14,5 | rbf | 0,928 | 0,990 | 0,623 | 0,971 | 0,142 | 0,500 |
| 7 | 0,4 | - | 15 | rbf | 0,943 | 0,993 | 0,678 | 0,986 | 0,119 | 0,500 |
| 8 | 0,35 | - | 15 | rbf | 0,932 | 0,990 | 0,636 | 0,971 | 0,139 | 0,500 |

(continua)

| Modelo | Métricas de Validação | | | | | | Métricas de Teste | | | | | Limiar Otimizado |
|--------|-----------------------|-------|----------|---------------|-------|---------------|-------------------|-------|----------|---------------|-------|------------------|
| | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão | Acurácia | AUROC | Precisão | Sensibilidade | Erro | |
| 1 | 0,845 | 0,798 | 0,217 | 0,333 | 0,364 | 0,500 | 0,897 | 0,750 | 0,000 | 0,000 | 0,334 | 0,146 |
| 2 | 0,839 | 0,795 | 0,150 | 0,267 | 0,365 | 0,500 | 0,897 | 0,764 | 0,000 | 0,000 | 0,334 | 0,145 |
| 3 | 0,839 | 0,788 | 0,150 | 0,267 | 0,366 | 0,500 | 0,897 | 0,779 | 0,000 | 0,000 | 0,333 | 0,143 |
| 4 | 0,852 | 0,793 | 0,217 | 0,333 | 0,366 | 0,500 | 0,897 | 0,764 | 0,000 | 0,000 | 0,327 | 0,117 |
| 5 | 0,819 | 0,795 | 0,150 | 0,267 | 0,367 | 0,500 | 0,897 | 0,779 | 0,000 | 0,000 | 0,350 | 0,182 |
| 6 | 0,845 | 0,788 | 0,150 | 0,267 | 0,367 | 0,500 | 0,897 | 0,779 | 0,000 | 0,000 | 0,332 | 0,141 |
| 7 | 0,845 | 0,788 | 0,197 | 0,267 | 0,368 | 0,500 | 0,897 | 0,771 | 0,000 | 0,000 | 0,327 | 0,116 |
| 8 | 0,845 | 0,786 | 0,150 | 0,267 | 0,369 | 0,500 | 0,897 | 0,779 | 0,000 | 0,000 | 0,332 | 0,140 |

(conclusão)

4.2.1.1. Classes Balanceadas

Com classes desbalanceadas não foi possível obter modelo capaz de prever a ocorrência de movimento de massa, que é caracterizado pela classe (1). Desta forma, para classes balanceadas e considerando o limiar padrão em 0,5, tem-se, na Tabela 53, os resultados das métricas de desempenho do modelo 1 (Tabela 52) para os conjuntos de treinamento, validação e de teste.

Tabela 53. Máquina de Vetores-Suporte – MP01: Classes Balanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,92 | 0,85 | 0,90 |
| AUROC | 0,99 | 0,80 | 0,75 |
| Precisão | 0,58 | 0,22 | 0,0 |
| Sensibilidade | 0,99 | 0,33 | 0,0 |
| Erro | 0,15 | 0,36 | 0,33 |

I. Quanto ao Treinamento e à Validação

As métricas de treinamento e validação, para classes balanceadas (Tabela 53), apresentaram evolução da sensibilidade em relação às das classes desbalanceadas (item (b) - APÊNDICE C). Este é um indicador de que o modelo, quando treinado com classes balanceadas, classifica corretamente mais amostras da classe (1). Entretanto, como o valor de precisão continua baixo, entende-se que o número de falsos positivos é representativo.

Ainda, comparando-se os resultados de classes desbalanceadas com os de balanceadas, a métrica erro de validação aumentou e ultrapassou o valor limite de referência 0,3, possivelmente pelo fato de que o modelo ainda apresenta dificuldade em classificar corretamente as amostras da classe (1) e/ou apresenta distribuição probabilística apenas em parte do intervalo de 0 a 1,0.

Em relação à comparação das métricas de treinamento e validação, para classes balanceadas (Tabela 53), observa-se que acurácia, AUROC, precisão e sensibilidade de validação são inferiores às de treinamento e o erro de validação, além de ser maior do que o erro de treinamento, é superior ao referencial limite de 0,3. Entende-se que o erro de validação (0,36), tomado em conjunto com o valor de AUROC (0,80), é indicativo de que a distribuição probabilística das amostras de validação pode não estar bem distribuída no intervalo 0 a 1, de modo que o limiar padrão de 0,5 impõe baixos valores de precisão (0,22) e de sensibilidade (0,33).

De qualquer forma, no que tange às diferenças entre erro e *AUROC* de treinamento e validação, é esperado que, em função da capacidade de generalização do modelo, o erro de validação seja maior do que o erro de treinamento. Entretanto, quando o erro ultrapassa o valor limite de referência, compreende-se que o modelo carece de melhoria. Desta forma, considerando-se que a modificação de hiperparâmetros não resulta mais em melhoria de desempenho, conclui-se que as limitações são principalmente impostas pela quantidade de amostras e o acentuado desbalanceamento original de classes (Tabela 40 e Tabela 41).

II. Quanto ao Teste

A *AUROC* de teste das classes balanceadas se aproxima da *AUROC* de validação e ambas são maiores do que 0,7 (Tabela 53). A comparação entre as *AUROC*, conduz à interpretação de que, com o balanceamento de classes, o modelo apresentou melhor desempenho em classificar amostras com as quais nunca teve contato. Nesta situação, ambas *AUROC* sinalizam que o modelo classificador está generalizando melhor. No caso do teste, *AUROC* igual a 0,75 significa que o modelo, na maioria das vezes (75%), classifica corretamente um caso positivo, atribuindo a ele uma probabilidade maior de pertencer à classe (1) do que de pertencer à classe (0).

Os modelos, de modo geral, além da predição de classe, podem responder em termos de probabilidade de um evento pertencer a uma ou a outra classe. A curva *ROC* é originada a partir da distribuição probabilística das amostras em combinação com os possíveis limiares (Figura 28 e Figura 29). A matriz de confusão é oriunda de determinado limiar admitido (Figura 30). No caso da sensibilidade e da precisão apresentadas na Tabela 53, o limiar utilizado é 0,5, este valor de limiar é adotado como padrão pela biblioteca Scikit-Learn (2007). Na Figura 70, é apresentada a matriz de confusão referente ao limiar padrão da qual são originadas precisão (0%), sensibilidade (0%) e acurácia (90%) apresentadas na Tabela 53.

| | | Realidade | |
|----------|---|------------|-----------|
| | | 0 | 1 |
| Previsão | 0 | 35 (VN) | 4 (FN) |
| | 1 | 0 (FP) | 0 (VP) |

Figura 70 – Máquina de Vetores-Suporte (MP01): Matriz de Confusão - Limiar Padrão - Teste

Desta forma, embora precisão e sensibilidade de teste da classe balanceada tenha resultado no valor 0,0 (zero), a *AUROC* igual a 75% sinaliza a existência de um limiar otimizado (item 2.4.2.1) em que se pode obter uma melhor combinação entre precisão e sensibilidade. Na Tabela 54, são apresentados os valores de precisão e sensibilidade de teste obtidos para o limiar otimizado do modelo 1 (Tabela 52) e na Figura 71 é apresentada a matriz de confusão da qual são originadas precisão (27%), sensibilidade (100%) e acurácia (72%).

Tabela 54. Máquina de Vetores-Suporte – MP01: Classes Balanceadas e Limiar Otimizado

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,92 | 0,85 | 0,72 |
| <i>AUROC</i> | 0,99 | 0,80 | 0,75 |
| Precisão | 0,58 | 0,22 | 0,27 |
| Sensibilidade | 0,99 | 0,33 | 1,0 |
| Erro | 0,15 | 0,36 | 0,33 |

Na Figura 71, tem-se a matriz de confusão do limiar otimizado igual a 0,15. Desta forma é possível comparar as Figura 70 e Figura 71 e observar que o ajuste do limiar pode resultar em variação da precisão, sensibilidade e da acurácia, tal como indicado numericamente na coluna “Teste” da Tabela 54.

| | | Realidade | |
|----------|---|------------|-----------|
| | | 0 | 1 |
| Previsão | 0 | 23 (VN) | 0 (FN) |
| | 1 | 11 (FP) | 4 (VP) |

Figura 71 – Máquina de Vetores-Suporte (MP01): Matriz de Confusão - Limiar Otimizado - Teste

De qualquer forma, embora as *AUROC* de validação e de teste (Tabela 53) se aproximem e este seja um fator indicativo de que o modelo apresenta maior capacidade de realizar classificações corretamente quando balanceado, as métricas de erro de validação e de teste estão próximas ao valor limite de referência 0,3. Sendo assim, entende-se que o modelo apresenta dificuldades em reconhecer a distribuição das amostras, como pode ser verificado por meio do valor 0,15 de limiar otimizado, o qual impacta na correta classificação de amostras da classe (1).

De modo geral, relaciona-se esta limitação de desempenho do modelo à quantidade de amostras para treinamento, validação e teste, fato agravado pelo desbalanceamento de classe, cuja quantidade de amostras da classe (1) é 10% do total de amostras (Tabela 40 e Tabela 41).

4.2.2 Modulação Temporal – MP02

A partir dos resultados da fase de treinamento e validação do modelo Máquina de Vetores-Suporte - MP02, realizou-se a pré-seleção dos modelos que apresentaram os menores erros de validação, os quais pertencem ao intervalo 0,3 a 0,39 e, também, cujos valores de *AUROC* são maiores ou iguais a 0,7 (item 2.4.2). Posteriormente, os modelos pré-selecionados foram submetidos à fase de teste. A partir dos resultados de teste, foram considerados os modelos que apresentaram os menores erros, e cujos valores de *AUROC* são maiores ou iguais a 0,7.

Na Tabela 55, estão elencados os hiperparâmetros dos modelos Máquina de Vetores-Suporte - MP02 que resultaram nas 8 (oito) melhores combinações de erro e de *AUROC*, nas etapas de validação e de teste, para a situação de classes balanceadas. A Tabela 55 permite a verificação de que os modelos apresentam:

- Erros de treinamento, que variam de 0,177 a 0,191, são inferiores aos erros de validação e de teste, e, também, inferiores aos limites referenciais de erro (item 3.5.3), que é de 0,3 para treinamento;
- Erros de validação entre 0,344 a 0,345 e erros de teste entre 0,350 a 0,355. No quesito de erros, os resultados de teste são próximos aos resultados de validação. Entretanto, ambos ultrapassam os limites referenciais de erro (item 3.5.3), que é de 0,3 para validação e de 0,14 para teste;
- As *AUROC* de treinamento variam de 0,971 a 0,978, as *AUROC* de validação variam de 0,719 a 0,726 e as *AUROC* de teste variam de 0,714 a 0,750. Neste caso, para todos os modelos (Tabela 55) as *AUROC* de treinamento são superiores às de validação e de teste;
- Valores de limiar otimizado, para o conjunto de teste, que estão entre 0,175 e 0,185. Este é um indicador de que os modelos, em relação ao conjunto de amostras com as quais nunca tiveram contato, não realizam a distribuição de classes no intervalo de 0 a 1. Neste caso, a distribuição está ocorrendo no intervalo de 0 a 0,2;

- Métricas acurácia, precisão e sensibilidade de teste iguais a 0,0 (zero), pois o limiar padrão em 0,5 impõe que todas as amostras, as quais estão distribuídas no intervalo de 0 a 0,3, sejam classificadas como classe (0).

Considera-se que o modelo 1 (Tabela 55), que foi obtido a partir do balanceamento de classes, apresenta o melhor desempenho com menor erro de validação e, também, com uma das maiores *AUROC* de validação. Adicionalmente, as métricas de erro de validação e de teste indicam que o modelo, mesmo após variações nos valores de hiperparâmetros, não atingiu o desempenho desejado, principalmente quando se observa que os menores erros de validação estão próximos ou acima de 0,3. De qualquer forma, no item 4.2.2.1 é realizada uma análise detalhada deste modelo.

Quanto à situação de classes desbalanceadas, a apresentação dos resultados no item (c) do APÊNDICE C objetiva fornecer uma referência do comportamento do modelo quando o desbalanceamento entre amostras da classe (0) e classe (1) é acentuado e, desta forma, para fins didáticos, caracterizar a necessidade de balancear as amostras no pré-processamento.

Tabela 55. Máquina de Vetores-Suporte – MP02: Hiperparâmetros, Métricas e Limiares

| Modelo | Hiperparâmetros | | | | Métricas de Treinamento | | | | | |
|--------|-----------------|--------|-------|--------|-------------------------|-------|----------|---------------|-------|---------------|
| | C | degree | gamma | kernel | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão |
| 1 | 0,9 | - | 19 | rbf | 0,933 | 0,974 | 0,690 | 0,857 | 0,183 | 0,500 |
| 2 | 0,8 | - | 19,5 | rbf | 0,935 | 0,972 | 0,693 | 0,857 | 0,187 | 0,500 |
| 3 | 0,8 | - | 19 | rbf | 0,933 | 0,972 | 0,685 | 0,857 | 0,189 | 0,500 |
| 4 | 0,9 | - | 19,5 | rbf | 0,935 | 0,975 | 0,695 | 0,857 | 0,181 | 0,500 |
| 5 | 1 | - | 19,5 | rbf | 0,941 | 0,978 | 0,720 | 0,886 | 0,177 | 0,500 |
| 6 | 0,8 | - | 18,5 | rbf | 0,937 | 0,971 | 0,698 | 0,857 | 0,191 | 0,500 |
| 7 | 0,9 | - | 18,5 | rbf | 0,933 | 0,974 | 0,690 | 0,857 | 0,185 | 0,500 |
| 8 | 1 | - | 19 | rbf | 0,941 | 0,977 | 0,720 | 0,886 | 0,178 | 0,500 |

(continua)

| Modelo | Métricas de Validação | | | | | | Métricas de Teste | | | | | Limiar Otimizado |
|--------|-----------------------|-------|----------|---------------|-------|---------------|-------------------|-------|----------|---------------|-------|------------------|
| | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão | Acurácia | AUROC | Precisão | Sensibilidade | Erro | |
| 1 | 0,852 | 0,724 | 0,167 | 0,200 | 0,344 | 0,500 | 0,897 | 0,736 | 0,000 | 0,000 | 0,352 | 0,179 |
| 2 | 0,858 | 0,721 | 0,167 | 0,200 | 0,344 | 0,500 | 0,897 | 0,721 | 0,000 | 0,000 | 0,355 | 0,185 |
| 3 | 0,858 | 0,721 | 0,167 | 0,200 | 0,344 | 0,500 | 0,897 | 0,721 | 0,000 | 0,000 | 0,353 | 0,182 |
| 4 | 0,852 | 0,719 | 0,167 | 0,200 | 0,344 | 0,500 | 0,897 | 0,743 | 0,000 | 0,000 | 0,354 | 0,183 |
| 5 | 0,852 | 0,719 | 0,167 | 0,200 | 0,344 | 0,500 | 0,897 | 0,743 | 0,000 | 0,000 | 0,353 | 0,184 |
| 6 | 0,865 | 0,726 | 0,200 | 0,200 | 0,345 | 0,500 | 0,897 | 0,714 | 0,000 | 0,000 | 0,352 | 0,179 |
| 7 | 0,852 | 0,719 | 0,167 | 0,200 | 0,345 | 0,500 | 0,897 | 0,743 | 0,000 | 0,000 | 0,350 | 0,175 |
| 8 | 0,852 | 0,721 | 0,167 | 0,200 | 0,345 | 0,500 | 0,897 | 0,750 | 0,000 | 0,000 | 0,351 | 0,180 |

(conclusão)

4.2.2.1. Classes Balanceadas

Com classes desbalanceadas não foi possível obter modelo capaz de prever a ocorrência de movimento de massa, que é caracterizado pela classe (1). Desta forma, para classes balanceadas e considerando o limiar padrão em 0,5, tem-se, na Tabela 56, os resultados das métricas de desempenho do modelo 1 (Tabela 55) para os conjuntos de treinamento, validação e de teste.

Tabela 56. Máquina de Vetores-Suporte – MP02: Classes Balanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,93 | 0,85 | 0,90 |
| AUROC | 0,97 | 0,72 | 0,74 |
| Precisão | 0,69 | 0,17 | 0,0 |
| Sensibilidade | 0,86 | 0,20 | 0,0 |
| Erro | 0,18 | 0,34 | 0,35 |

I. Quanto ao Treinamento e à Validação

As métricas de treinamento e validação, para classes balanceadas, apresentaram evolução da sensibilidade em relação às das classes desbalanceadas (item (c) - APÊNDICE C). Este é um indicador de que o modelo, quando treinado com classes balanceadas, classifica corretamente mais amostras da classe (1). Entretanto, como o valor de precisão continua baixo, entende-se que o número de falsos positivos é representativo.

Ainda, comparando-se os resultados de classes desbalanceadas com os de balanceadas, a métrica erro de validação aumentou e ultrapassou o valor limite de referência 0,3, possivelmente pelo fato de que o modelo ainda apresenta dificuldade em classificar corretamente as amostras da classe (1) e/ou apresenta distribuição probabilística apenas em parte do intervalo de 0 a 1,0.

Em relação à comparação das métricas de treinamento e validação, para classes balanceadas (Tabela 56), observa-se que acurácia, AUROC, precisão e sensibilidade de validação são inferiores às de treinamento e o erro de validação, além de ser maior do que o erro de treinamento, é superior ao referencial limite de 0,3. Entende-se que o erro de validação (0,34), tomado em conjunto com o valor de AUROC (0,72), é indicativo de que a distribuição probabilística das amostras de validação pode não estar bem distribuída no intervalo 0 a 1, de modo que o limiar padrão de 0,5 impõe baixos valores de precisão (0,17) e de sensibilidade (0,20).

De qualquer forma, no que tange às diferenças entre erro e *AUROC* de treinamento e validação, é esperado que, em função da capacidade de generalização do modelo, o erro de validação seja maior do que o erro de treinamento. Entretanto, quando o erro ultrapassa o valor limite de referência, compreende-se que o modelo carece de melhoria. Desta forma, considerando-se que a modificação de hiperparâmetros não resulta mais em melhoria de desempenho, conclui-se que as limitações são principalmente impostas pela quantidade de amostras e o acentuado desbalanceamento original de classes (Tabela 40 e Tabela 41).

II. Quanto ao Teste

A *AUROC* de teste das classes balanceadas se aproxima da *AUROC* de validação e ambas são maiores do que 0,7 (Tabela 56). A comparação entre as *AUROC*, conduz à interpretação de que, com o balanceamento de classes, o modelo apresentou melhor desempenho em classificar amostras com as quais nunca teve contato. Nesta situação, ambas *AUROC* sinalizam que o modelo classificador está generalizando melhor. No caso do teste, *AUROC* igual a 0,74 significa que o modelo, na maioria das vezes (74%), classifica corretamente um caso positivo, atribuindo a ele uma probabilidade maior de pertencer à classe (1) do que de pertencer à classe (0).

Os modelos, de modo geral, além da predição de classe, podem responder em termos de probabilidade de um evento pertencer a uma ou a outra classe. A curva *ROC* é originada a partir da distribuição probabilística das amostras em combinação com os possíveis limiares (Figura 28 e Figura 29). A matriz de confusão é oriunda de determinado limiar admitido (Figura 30). No caso da sensibilidade e da precisão apresentadas na Tabela 56, o limiar utilizado é 0,5, este valor de limiar é adotado como padrão pela biblioteca Scikit-Learn (2007). Na Figura 72, é apresentada a matriz de confusão referente ao limiar padrão da qual são originadas precisão (0%), sensibilidade (0%) e acurácia (90%) apresentadas na Tabela 56.

| | | Realidade | |
|----------|---|------------|-----------|
| | | 0 | 1 |
| Previsão | 0 | 35 (VN) | 4 (FN) |
| | 1 | 0 (FP) | 0 (VP) |

Figura 72 – Máquina de Vetores-Suporte (MP02): Matriz de Confusão - Limiar Padrão - Teste

Desta forma, embora precisão e sensibilidade de teste da classe balanceada tenha resultado no valor 0,0 (zero), a *AUROC* igual a 74% sinaliza a existência de um limiar otimizado (item 2.4.2.1) em que se pode obter uma melhor combinação entre precisão e sensibilidade. Na Tabela 57 são apresentados os valores de precisão e sensibilidade de teste obtidos para o limiar otimizado do modelo 1 (Tabela 55) e, na Figura 73, é apresentada a matriz de confusão da qual são originadas precisão (19%), sensibilidade (100%) e acurácia (56%).

Tabela 57. Máquina de Vetores-Suporte – MP02: Classes Balanceadas e Limiar Otimizado

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,93 | 0,85 | 0,56 |
| <i>AUROC</i> | 0,97 | 0,72 | 0,74 |
| Precisão | 0,69 | 0,17 | 0,19 |
| Sensibilidade | 0,86 | 0,20 | 1,00 |
| Erro | 0,18 | 0,34 | 0,35 |

Na Figura 73, tem-se a matriz de confusão do limiar otimizado igual a 0,18. Desta forma é possível comparar as Figura 72 e Figura 73 e observar que o ajuste do limiar pode resultar em variação da precisão, sensibilidade e da acurácia, tal como indicado numericamente na coluna “Teste” da Tabela 57.

| | | Realidade | |
|----------|---|------------|-----------|
| | | 0 | 1 |
| Previsão | 0 | 18 (VN) | 0 (FN) |
| | 1 | 17 (FP) | 4 (VP) |

Figura 73 – Máquina de Vetores-Suporte (MP02): Matriz de Confusão - Limiar Otimizado - Teste

De qualquer forma, embora as *AUROC* de validação e de teste (Tabela 56) se aproximem e este seja um fator indicativo de que o modelo apresenta maior capacidade de realizar classificações corretamente quando balanceado, as métricas de erro de validação e de teste ultrapassaram o valor limite de referência 0,3. Sendo assim, entende-se que o modelo apresenta dificuldades em reconhecer a distribuição das amostras, como pode ser verificado por meio do valor 0,32 de limiar otimizado, o qual impacta na correta classificação de amostras da classe (1).

De modo geral, relaciona-se esta limitação de desempenho do modelo à quantidade de amostras para treinamento, validação e teste, fato agravado pelo desbalanceamento de classe, cuja quantidade de amostras da classe (1) é 10% do total de amostras (Tabela 40 e Tabela 41).

4.3 Modelos Perceptron Multicamadas (*Multi-layer Perceptron - MLP*)

Para as MP01 e MP02 foram realizadas as etapas de treinamento, validação e teste dos modelos utilizando combinações dos hiperparâmetros apresentados na Tabela 44.

4.3.1 Modulação Temporal – MP01

Com os resultados da fase de treinamento e validação, realizou-se a pré-seleção dos modelos que apresentaram os menores erros de validação, os quais pertencem ao intervalo 0,3 a 0,39 e, também, cujos valores de *AUROC* são maiores ou iguais a 0,7 (item 2.4.2). Posteriormente, os modelos pré-selecionados foram submetidos à fase de teste. A partir dos resultados de teste, foram considerados os modelos que apresentaram os menores erros, e cujos valores de *AUROC* são maiores ou iguais a 0,7.

Na Tabela 58, estão elencados os hiperparâmetros dos modelos Perceptron Multicamadas - MP01 que resultaram nas 8 (oito) melhores combinações de erro e de *AUROC*, nas etapas de validação e de teste, para a situação de classes balanceadas. A Tabela 58 permite a verificação de que os modelos apresentam:

- Erros de treinamento, que variam de 0,293 a 0,354, são inferiores aos erros de validação e de teste, mas são próximos ou superiores aos limites referenciais de erro (item 3.5.3), que é de 0,3 para treinamento;
- Erros de validação entre 0,334 a 0,372 e erros de teste entre 0,328 a 0,344. No quesito de erros, os resultados de teste se aproximam dos resultados de validação. Embora ambos estejam próximos ou ultrapassem os limites referenciais de erro (item 3.5.3), que é de 0,3 para validação e de 0,14 para teste;

- As *AUROC* de treinamento variam de 0,941 a 0,960, as *AUROC* de validação variam de 0,890 a 0,924 e as *AUROC* de teste variam de 0,779 a 0,821. Para todos os modelos (Tabela 58), as *AUROC* de treinamento são superiores às de validação e às de teste e, também, as *AUROC* de validação são superiores às de teste;
- Valores de limiar otimizado, para o conjunto de teste, que estão entre 0,058 e 0,130. Este é um indicador de que os modelos, em relação ao conjunto de amostras com as quais nunca tiveram contato, não realizam a distribuição de classes no intervalo de 0 a 1. Neste caso, a distribuição está ocorrendo no intervalo de 0 a 0,2;
- Métricas acurácia, precisão e sensibilidade de teste iguais a 0,0 (zero), pois o limiar padrão em 0,5 impõe que todas as amostras, as quais estão distribuídas no intervalo de 0 a 0,2, sejam classificadas como classe (0).

Considera-se que o modelo 1 (Tabela 58), que foi obtido a partir do balanceamento de classes, apresenta o melhor desempenho com menor erro de validação e, também, com a maior *AUROC* de validação. Adicionalmente, as métricas de erro de validação e de teste indicam que o modelo, mesmo após variações nos valores de hiperparâmetros, não atingiu o desempenho desejado, principalmente quando se observa que os menores erros de validação estão próximos ou acima de 0,3. De qualquer forma, no item 4.3.1.1 é realizada uma análise detalhada deste modelo.

Quanto à situação de classes desbalanceadas, a apresentação dos resultados no item (d) do APÊNDICE C objetiva fornecer uma referência do comportamento do modelo quando o desbalanceamento entre amostras da classe (0) e classe (1) é acentuado e, desta forma, para fins didáticos, caracterizar a necessidade de balancear as amostras no pré-processamento.

Tabela 58. Perceptron Multicamadas – MP01: Hiperparâmetros, Métricas e Limiares

| Modelo | Hiperparâmetros | | | | | | Métricas de Treinamento | | | | | |
|--------|--------------------|------------|---------------|--------|-------|----------|-------------------------|-------|----------|---------------|-------|---------------|
| | hidden layer sizes | activation | learning rate | solver | alpha | max_iter | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão |
| 1 | 16 | relu | adaptive | lbfgs | 1,5 | 200 | 0,862 | 0,956 | 0,449 | 0,943 | 0,307 | 0,500 |
| 2 | 18 | relu | adaptive | lbfgs | 1,25 | 500 | 0,878 | 0,959 | 0,483 | 0,957 | 0,293 | 0,500 |
| 3 | 14 | relu | adaptive | lbfgs | 1,5 | 500 | 0,863 | 0,956 | 0,454 | 0,957 | 0,305 | 0,500 |
| 4 | 20 | relu | adaptive | lbfgs | 1,5 | 500 | 0,875 | 0,960 | 0,477 | 0,957 | 0,302 | 0,500 |
| 5 | 16 | relu | adaptive | lbfgs | 1,75 | 200 | 0,860 | 0,944 | 0,446 | 0,929 | 0,339 | 0,500 |
| 6 | 12 | relu | adaptive | lbfgs | 1,25 | 200 | 0,855 | 0,941 | 0,440 | 0,929 | 0,330 | 0,500 |
| 7 | 14 | relu | constant | lbfgs | 2 | 200 | 0,842 | 0,941 | 0,414 | 0,914 | 0,354 | 0,500 |
| 8 | 20 | relu | adaptive | lbfgs | 2 | 500 | 0,859 | 0,945 | 0,443 | 0,929 | 0,347 | 0,500 |

(continua)

| Modelo | Métricas de Validação | | | | | | Métricas de Teste | | | | | Limiar Otimizado |
|--------|-----------------------|-------|----------|---------------|-------|---------------|-------------------|-------|----------|---------------|-------|------------------|
| | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão | Acurácia | AUROC | Precisão | Sensibilidade | Erro | |
| 1 | 0,865 | 0,902 | 0,378 | 0,667 | 0,334 | 0,500 | 0,897 | 0,838 | 0,000 | 0,000 | 0,328 | 0,084 |
| 2 | 0,852 | 0,895 | 0,319 | 0,600 | 0,334 | 0,500 | 0,897 | 0,779 | 0,000 | 0,000 | 0,331 | 0,130 |
| 3 | 0,845 | 0,924 | 0,310 | 0,600 | 0,341 | 0,500 | 0,897 | 0,793 | 0,000 | 0,000 | 0,328 | 0,112 |
| 4 | 0,871 | 0,917 | 0,394 | 0,667 | 0,342 | 0,500 | 0,897 | 0,800 | 0,000 | 0,000 | 0,328 | 0,109 |
| 5 | 0,858 | 0,910 | 0,392 | 0,733 | 0,361 | 0,500 | 0,897 | 0,821 | 0,000 | 0,000 | 0,328 | 0,089 |
| 6 | 0,852 | 0,890 | 0,322 | 0,600 | 0,363 | 0,500 | 0,897 | 0,779 | 0,000 | 0,000 | 0,331 | 0,130 |
| 7 | 0,877 | 0,907 | 0,430 | 0,800 | 0,364 | 0,500 | 0,897 | 0,821 | 0,000 | 0,000 | 0,331 | 0,082 |
| 8 | 0,877 | 0,890 | 0,430 | 0,800 | 0,372 | 0,500 | 0,897 | 0,821 | 0,000 | 0,000 | 0,344 | 0,058 |

(conclusão)

4.3.1.1. Classes Balanceadas

Com classes desbalanceadas não foi possível obter modelo capaz de prever a ocorrência de movimento de massa, que é caracterizado pela classe (1). Desta forma, para classes balanceadas e considerando o limiar padrão em 0,5, tem-se, na Tabela 59, os resultados das métricas de desempenho do modelo 1 (Tabela 58) para os conjuntos de treinamento, validação e de teste.

Tabela 59. Perceptron Multicamadas – MP01: Classes Balanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,86 | 0,86 | 0,90 |
| AUROC | 0,96 | 0,90 | 0,84 |
| Precisão | 0,45 | 0,38 | 0,0 |
| Sensibilidade | 0,94 | 0,67 | 0,0 |
| Erro | 0,31 | 0,33 | 0,33 |

I. Quanto ao Treinamento e à Validação

As métricas de treinamento e validação, para classes balanceadas (Tabela 59), apresentaram evolução da sensibilidade em relação às das classes desbalanceadas (no item (d) - APÊNDICE C). Este é um indicador de que o modelo, quando treinado com classes balanceadas, classifica corretamente mais amostras da classe (1). Entretanto, como o valor de precisão continua baixo, entende-se que o número de falsos positivos é representativo.

Ainda, comparando-se os resultados de classes desbalanceadas com os de balanceadas, a métrica erro de validação aumentou e ultrapassou o valor limite de referência 0,3, possivelmente pelo fato de que o modelo ainda apresenta dificuldade em classificar corretamente as amostras da classe (1) e/ou apresenta distribuição probabilística apenas em parte do intervalo de 0 a 1,0.

Em relação à comparação das métricas de treinamento e validação, para classes balanceadas (Tabela 59), observa-se que acurácia, AUROC, precisão e sensibilidade de validação são inferiores às de treinamento e o erro de validação, além de ser maior do que o erro de treinamento, é superior ao referencial limite de 0,3. Entende-se que o erro de validação (0,33), tomado em conjunto com os valores de AUROC (0,90) e sensibilidade (0,67) é indicativo de que o modelo, embora apresente sinais de uma melhor distribuição probabilística, com amostras verdadeiro-positivos entre o intervalo 0,5 a 1,0, resulta em um quantidade representativa de falsos-positivos, fato que reflete em baixa precisão (0,38).

De qualquer forma, no que tange às diferenças entre erro e *AUROC* de treinamento e validação, é esperado que, em função da capacidade de generalização do modelo, o erro de validação seja maior do que o erro de treinamento. Entretanto, quando o erro ultrapassa o valor limite de referência, compreende-se que o modelo carece de melhoria. Desta forma, considerando-se que a modificação de hiperparâmetros não resulta mais em melhoria de desempenho, conclui-se que as limitações são principalmente impostas pela quantidade de amostras e o acentuado desbalanceamento original de classes (Tabela 40 e Tabela 41).

II. Quanto ao Teste

A *AUROC* de teste das classes balanceadas se aproxima da *AUROC* de validação e ambas são maiores do que 0,7 (Tabela 59). A comparação entre as *AUROC*, conduz à interpretação de que, com o balanceamento de classes, o modelo apresentou melhor desempenho em classificar amostras com as quais nunca teve contato. Nesta situação, ambas *AUROC* sinalizam que o modelo classificador está generalizando melhor. No caso do teste, *AUROC* igual a 0,84 significa que o modelo, na maioria das vezes (84%), classifica corretamente um caso positivo, atribuindo a ele uma probabilidade maior de pertencer à classe (1) do que de pertencer à classe (0).

Os modelos, de modo geral, além da predição de classe, podem responder em termos de probabilidade de um evento pertencer a uma ou a outra classe. A curva *ROC* é originada a partir da distribuição probabilística das amostras em combinação com os possíveis limiares (Figura 28 e Figura 29). A matriz de confusão é oriunda de determinado limiar admitido (Figura 30). No caso da sensibilidade e da precisão apresentadas na Tabela 59, o limiar utilizado é 0,5, este valor de limiar é adotado como padrão pela biblioteca Scikit-Learn (2007). Na Figura 74, é apresentada a matriz de confusão referente ao limiar padrão da qual são originadas precisão (0%), sensibilidade (0%) e acurácia (90%) apresentadas na Tabela 59.

| | | Realidade | |
|----------|---|------------|-----------|
| | | 0 | 1 |
| Previsão | 0 | 35 (VN) | 4 (FN) |
| | 1 | 0 (FP) | 0 (VP) |

Figura 74 – Perceptron Multicamadas (MP01): Matriz de Confusão - Limiar Padrão - Teste

Desta forma, embora precisão e sensibilidade de teste da classe balanceada tenha resultado no valor 0,0 (zero), a *AUROC* igual a 84% sinaliza a existência de um limiar otimizado (item 2.4.2.1) em que se pode obter uma melhor combinação entre precisão e sensibilidade. Na Tabela 60, são apresentados os valores de precisão e sensibilidade de teste obtidos para o limiar otimizado do modelo 1 (Tabela 58) e na Figura 75 é apresentada a matriz de confusão da qual são originadas precisão (33%), sensibilidade (100%) e acurácia (90%).

Tabela 60. Perceptron Multicamadas – MP01: Classes Balanceadas e Limiar Otimizado

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,86 | 0,86 | 0,90 |
| <i>AUROC</i> | 0,96 | 0,90 | 0,84 |
| Precisão | 0,45 | 0,38 | 0,33 |
| Sensibilidade | 0,94 | 0,67 | 1,00 |
| Erro | 0,31 | 0,33 | 0,33 |

Na Figura 75, tem-se a matriz de confusão do limiar otimizado igual a 0,08. Desta forma é possível comparar as Figura 74 e Figura 75 e observar que o ajuste do limiar pode resultar em variação da precisão, sensibilidade e da acurácia, tal como indicado numericamente na coluna “Teste” da Tabela 60.

| | | Realidade | |
|----------|---|------------|-----------|
| | | 0 | 1 |
| Previsão | 0 | 27 (VN) | 0 (FN) |
| | 1 | 8 (FP) | 4 (VP) |

Figura 75 – Perceptron Multicamadas (MP01): Matriz de Confusão - Limiar Otimizado - Teste

De qualquer forma, embora as *AUROC* de validação e de teste (Tabela 59) se aproximem e este seja um fator indicativo de que o modelo apresenta maior capacidade de realizar classificações corretamente quando balanceado, as métricas de erro de validação e de teste estão próximas ao valor limite de referência 0,3. Sendo assim, entende-se que o modelo apresenta dificuldades em reconhecer a distribuição das amostras, como pode ser verificado por meio do valor 0,08 de limiar otimizado, o qual impacta na correta classificação de amostras da classe (1).

De modo geral, relaciona-se esta limitação de desempenho do modelo à quantidade de amostras para treinamento, validação e teste, fato agravado pelo desbalanceamento de classe, cuja quantidade de amostras da classe (1) é 10% do total de amostras (Tabela 40 e Tabela 41).

4.3.2 Modulação Temporal – MP02

A partir dos resultados da fase de treinamento e validação do modelo Perceptron Multicamadas - MP02, realizou-se a pré-seleção dos modelos que apresentaram os menores erros de validação, os quais pertencem ao intervalo 0,4 a 0,49 e, também, cujos valores de *AUROC* são maiores ou iguais a 0,7 (item 2.4.2). Posteriormente, os modelos pré-selecionados foram submetidos à fase de teste. A partir dos resultados de teste, foram considerados os modelos que apresentaram os menores erros, e cujos valores de *AUROC* são maiores ou iguais a 0,7.

Na Tabela 61, estão elencados os hiperparâmetros dos modelos Perceptron Multicamadas - MP02 que resultaram nas 8 (oito) melhores combinações de erro e de *AUROC*, nas etapas de validação e de teste, para a situação de classes balanceadas. A Tabela 61 permite a verificação de que os modelos apresentam:

- Erros de treinamento, que variam de 0,361 a 0,375, são inferiores aos erros de validação e de teste e, também, superiores aos limites referenciais de erro (item 3.5.3), que é de 0,3 para treinamento;
- Erros de validação entre 0,370 a 0,390 e erros de teste entre 0,401 a 0,453. No quesito de erros, os resultados de teste são inferiores do que os resultados de validação. Entretanto, ambos ultrapassam os limites referenciais de erro (item 3.5.3), que é de 0,3 para validação e de 0,14 para teste;
- As *AUROC* de treinamento variam de 0,908 a 0,920, as *AUROC* de validação variam de 0,862 a 0,871 e as *AUROC* de teste variam de 0,357 a 0,400. Neste caso, para todos os modelos (Tabela 61) as *AUROC* de treinamento são superiores às de validação e de teste;
- Valores de limiar otimizado, para o conjunto de teste, que estão entre 0,013 e 0,025. Este é um indicador de que os modelos, em relação ao conjunto de amostras com as quais nunca tiveram contato, não realizam a distribuição de classes no intervalo de 0 a 1. Neste caso, a distribuição está ocorrendo no intervalo de 0 a 0,1;

- Métricas acurácia, precisão e sensibilidade de teste iguais a 0,0 (zero), pois o limiar padrão em 0,5 impõe que todas as amostras, as quais estão distribuídas no intervalo de 0 a 0,3, sejam classificadas como classe (0).

Considera-se que o modelo 1 (Tabela 61), que foi obtido a partir do balanceamento de classes, apresenta o melhor desempenho com menor erro de validação em combinação, embora sua *AUROC* de validação não seja uma das maiores. Adicionalmente, as métricas de erro de validação e de teste indicam que o modelo, mesmo após variações nos valores de hiperparâmetros, não atingiu o desempenho desejado, principalmente quando se observa que os menores erros de validação estão acima de 0,3. De qualquer forma, no item 4.3.2.1 é realizada uma análise detalhada deste modelo.

Quanto à situação de classes desbalanceadas, a apresentação dos resultados no item (e) do APÊNDICE C objetiva fornecer uma referência do comportamento do modelo quando o desbalanceamento entre amostras da classe (0) e classe (1) é acentuado e, desta forma, para fins didáticos, caracterizar a necessidade de balancear as amostras no pré-processamento.

Tabela 61. Perceptron Multicamadas – MP02: Hiperparâmetros, Métricas e Limiares

| Modelo | Hiperparâmetros | | | | | | Métricas de Treinamento | | | | | |
|--------|--------------------|------------|---------------|--------|-------|----------|-------------------------|-------|----------|---------------|-------|---------------|
| | hidden layer sizes | activation | learning rate | solver | alpha | max_iter | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão |
| 1 | 16 | relu | constant | lbfgs | 1 | 200 | 0,844 | 0,908 | 0,405 | 0,757 | 0,364 | 0,500 |
| 2 | 16 | relu | adaptive | lbfgs | 1 | 200 | 0,844 | 0,908 | 0,405 | 0,757 | 0,364 | 0,500 |
| 3 | 20 | relu | constant | lbfgs | 1 | 200 | 0,860 | 0,920 | 0,443 | 0,814 | 0,361 | 0,500 |
| 4 | 20 | relu | adaptive | lbfgs | 1 | 200 | 0,860 | 0,920 | 0,443 | 0,814 | 0,361 | 0,500 |
| 5 | 18 | relu | constant | lbfgs | 1 | 200 | 0,857 | 0,917 | 0,437 | 0,829 | 0,366 | 0,500 |
| 6 | 18 | relu | adaptive | lbfgs | 1 | 200 | 0,857 | 0,917 | 0,437 | 0,829 | 0,366 | 0,500 |
| 7 | 14 | relu | constant | lbfgs | 1 | 200 | 0,849 | 0,912 | 0,421 | 0,800 | 0,375 | 0,500 |
| 8 | 14 | relu | adaptive | lbfgs | 1 | 200 | 0,849 | 0,912 | 0,421 | 0,800 | 0,375 | 0,500 |

(continua)

| Modelo | Métricas de Validação | | | | | | Métricas de Teste | | | | | Limiar Otimizado |
|--------|-----------------------|-------|----------|---------------|-------|---------------|-------------------|-------|----------|---------------|-------|------------------|
| | Acurácia | AUROC | Precisão | Sensibilidade | Erro | Limiar Padrão | Acurácia | AUROC | Precisão | Sensibilidade | Erro | |
| 1 | 0,858 | 0,862 | 0,377 | 0,733 | 0,370 | 0,500 | 0,897 | 0,400 | 0,000 | 0,000 | 0,453 | 0,013 |
| 2 | 0,858 | 0,862 | 0,377 | 0,733 | 0,370 | 0,500 | 0,897 | 0,400 | 0,000 | 0,000 | 0,453 | 0,013 |
| 3 | 0,871 | 0,871 | 0,411 | 0,733 | 0,380 | 0,500 | 0,897 | 0,379 | 0,000 | 0,000 | 0,419 | 0,020 |
| 4 | 0,871 | 0,871 | 0,411 | 0,733 | 0,380 | 0,500 | 0,897 | 0,379 | 0,000 | 0,000 | 0,419 | 0,020 |
| 5 | 0,845 | 0,871 | 0,361 | 0,733 | 0,387 | 0,500 | 0,897 | 0,400 | 0,000 | 0,000 | 0,446 | 0,015 |
| 6 | 0,845 | 0,871 | 0,361 | 0,733 | 0,387 | 0,500 | 0,897 | 0,400 | 0,000 | 0,000 | 0,446 | 0,015 |
| 7 | 0,858 | 0,869 | 0,361 | 0,667 | 0,390 | 0,500 | 0,897 | 0,357 | 0,000 | 0,000 | 0,401 | 0,025 |
| 8 | 0,858 | 0,869 | 0,361 | 0,667 | 0,390 | 0,500 | 0,897 | 0,357 | 0,000 | 0,000 | 0,401 | 0,025 |

(conclusão)

4.3.2.1. Classes Balanceadas

Com classes desbalanceadas não foi possível obter modelo capaz de prever a ocorrência de movimento de massa, que é caracterizado pela classe (1). Desta forma, para classes balanceadas e considerando o limiar padrão em 0,5, tem-se, na Tabela 62, os resultados das métricas de desempenho do modelo 1 (Tabela 61) para os conjuntos de treinamento, validação e de teste.

Tabela 62. Perceptron Multicamadas – MP02: Classes Balanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,84 | 0,82 | 0,90 |
| AUROC | 0,91 | 0,83 | 0,40 |
| Precisão | 0,41 | 0,38 | 0,0 |
| Sensibilidade | 0,76 | 0,73 | 0,0 |
| Erro | 0,38 | 0,39 | 0,45 |

I. Quanto ao Treinamento e à Validação

As métricas de treinamento e validação, para classes balanceadas (Tabela 62), apresentaram evolução da sensibilidade em relação às das classes desbalanceadas (item (e) - APÊNDICE C). Este é um indicador de que o modelo, quando treinado com classes balanceadas, classifica corretamente mais amostras da classe (1). Entretanto, como o valor de precisão continua baixo, entende-se que o número de falsos positivos é representativo.

Ainda, comparando-se os resultados de classes desbalanceadas com os de balanceadas, a métrica erro de validação aumentou e ultrapassou o valor limite de referência 0,3, possivelmente pelo fato de que o modelo ainda apresenta dificuldade em classificar corretamente as amostras da classe (1) e/ou apresenta distribuição probabilística apenas em parte do intervalo de 0 a 1,0.

Em relação à comparação das métricas de treinamento e validação, para classes balanceadas (Tabela 62), observa-se que acurácia, AUROC, precisão e sensibilidade de validação são inferiores às de treinamento e o erro de validação, além de ser maior do que o erro de treinamento, é superior ao referencial limite de 0,3. Entende-se que o erro de validação (0,38), tomado em conjunto com os valores de AUROC (0,83) e sensibilidade (0,73) é indicativo de que o modelo, embora apresente sinais de uma melhor distribuição probabilística, com amostras verdadeiro-positivos entre o intervalo 0,5 a 1,0, resulta em um quantidade representativa de falsos-positivos, fato que reflete em baixa precisão (0,38).

De qualquer forma, no que tange às diferenças entre erro e *AUROC* de treinamento e validação, é esperado que, em função da capacidade de generalização do modelo, o erro de validação seja maior do que o erro de treinamento. Entretanto, quando o erro ultrapassa o valor limite de referência, compreende-se que o modelo carece de melhoria. Desta forma, considerando-se que a modificação de hiperparâmetros não resulta mais em melhoria de desempenho, conclui-se que as limitações são principalmente impostas pela quantidade de amostras e o acentuado desbalanceamento original de classes (Tabela 40 e Tabela 41).

II. Quanto ao Teste

Em termos de classes balanceadas (Tabela 62), as métricas das amostras de teste, principalmente *AUROC* (0,4) e erro (0,45), indicam que o modelo, para amostras com as quais nunca teve contato, não é capaz de realizar boas previsões. Ainda, a maioria das amostras do grupo de teste pertence à classe (0), aproximadamente 90% das amostras. Neste caso, a obtenção de 90% de acurácia, indica que o modelo classificou corretamente as amostras pertencentes à classe (0). De qualquer forma, embora este modelo não consiga prever a ocorrência de movimentos de massa, a seguir serão apresentados, para fins didáticos, as matrizes de confusão para limiar padrão e para o limiar otimizado.

Os modelos, de modo geral, além da previsão de classe, podem responder em termos de probabilidade de um evento pertencer a uma ou a outra classe. A curva *ROC* é originada a partir da distribuição probabilística das amostras em combinação com os possíveis limiares (Figura 28 e Figura 29). A matriz de confusão é oriunda de determinado limiar admitido (Figura 30). No caso da sensibilidade e da precisão apresentadas na Tabela 62, o limiar utilizado é 0,5, este valor de limiar é adotado como padrão pela biblioteca Scikit-Learn (2007). Na Figura 76, é apresentada a matriz de confusão referente ao limiar padrão da qual são originadas precisão (0%), sensibilidade (0%) e acurácia (90%) apresentadas na Tabela 62.

| | | Realidade | |
|----------|---|------------|-----------|
| | | 0 | 1 |
| Previsão | 0 | 35 (VN) | 4 (FN) |
| | 1 | 0 (FP) | 0 (VP) |

Figura 76 – Perceptron Multicamadas (MP02): Matriz de Confusão - Limiar Padrão - Teste

Desta forma, embora a *AUROC* igual a 40% sinalize que o modelo não apresenta capacidade de realizar predições, para fins de didáticos, são apresentados na Tabela 63 os valores de precisão e sensibilidade de teste obtidos para o limiar otimizado do modelo 1 (Tabela 61) e, na Figura 77, é apresentada a matriz de confusão da qual são originadas precisão (12%), sensibilidade (75%) e acurácia (38%).

Tabela 63. Perceptron Multicamadas – MP02: Classes Balanceadas e Limiar Otimizado

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,84 | 0,82 | 0,38 |
| <i>AUROC</i> | 0,91 | 0,83 | 0,40 |
| Precisão | 0,41 | 0,38 | 0,12 |
| Sensibilidade | 0,76 | 0,73 | 0,75 |
| Erro | 0,38 | 0,39 | 0,45 |

Na Figura 77, tem-se a matriz de confusão do limiar otimizado igual a 0,013. Desta forma é possível comparar as Figura 76 e Figura 77 e observar que o ajuste do limiar pode resultar em variação da precisão, sensibilidade e da acurácia, tal como indicado numericamente na coluna “Teste” da Tabela 63. Além disto, na Figura 77 é possível verificar que, uma vez que a *AUROC* de teste é 0,4, o limiar otimizado resulta em aumento dos falsos-positivos.

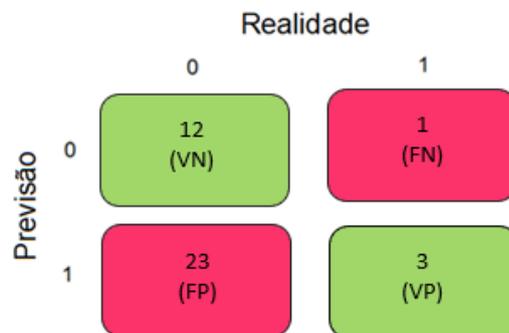


Figura 77 – Perceptron Multicamadas (MP02): Matriz de Confusão - Limiar Otimizado - Teste

De qualquer forma, embora as *AUROC* de validação (Tabela 62) possa ser um fator indicativo de que o modelo apresenta maior capacidade de realizar classificações corretamente quando balanceado, as métricas de erro de validação e de teste ultrapassaram o valor limite de referência 0,3 e a *AUROC* de teste é inferior a 0,7. Esta limitação de desempenho do modelo pode estar ligada à quantidade de amostras e ao desbalanceamento de classe (Tabela 40 e Tabela 41), ou pode se relacionar com os tipos de fatores que compõem a MP02.

5 COMPARAÇÃO DOS RESULTADOS E APLICAÇÃO DO MODELO

5.1 Modulação de Precipitação

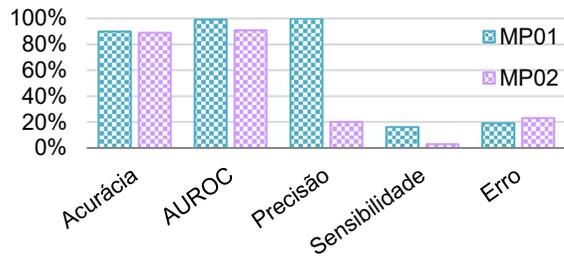
Os resultados de desempenho dos modelos Floresta Aleatória (*Random Forest*), Máquina de Vetores-Suporte (*Support Vector Machine*) e Perceptron Multicamadas (*Multi-layer Perceptron*), conforme apresentado no item 4, seguem apresentados em formato gráfico. Esta forma de agrupamento permite a comparação do desempenho de um mesmo modelo de acordo com os fatores utilizados (MP01 e MP02) para treinamento, validação e teste.

5.1.1 Floresta Aleatória (*Random Forest - RF*)

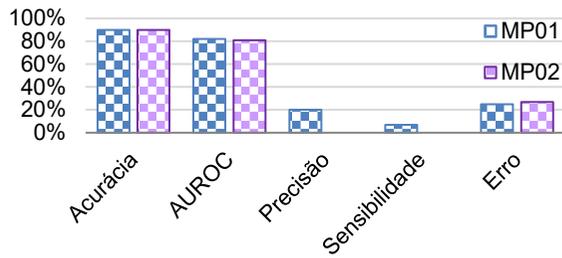
Nas Figura 78 a Figura 80 estão compilados os resultados das métricas acurácia, *AUROC*, precisão e sensibilidade obtidos para os dois melhores modelos Floresta Aleatória (*Random Forest*), considerando-se as modulações MP01(Tabela 46, Tabela 47 e Tabela 48) e MP02 (Tabela 73, Tabela 50 e Tabela 51). Os resultados para classes desbalanceadas (Figura 78), embora apresentados para fins de composição do quadro de resultados, não são considerados como referência devido sua resposta tendenciosa em favor da classe majoritária (item 4.1 e APÊNDICE C).

Tratando-se de classes balanceadas, na Figura 79, pode-se observar que, no treinamento, na validação e no teste, a MP01 apresenta iguais ou melhores resultados de desempenho do que os da MP02. Ademais, como a otimização de limiar foi realizada apenas na fase de teste, a Figura 80 (c) reflete mudanças das métricas e, de forma similar, seus resultados para a MP01 são melhores ou iguais aos resultados para a MP02. Sendo assim, comparando-se as respostas do modelo Floresta Aleatória MP01 com o modelo Floresta Aleatória MP02, entende-se que os fatores adotados na MP01 apresentam maior potencial para desenvolvimento de modelos do que os fatores que compõem a MP02.

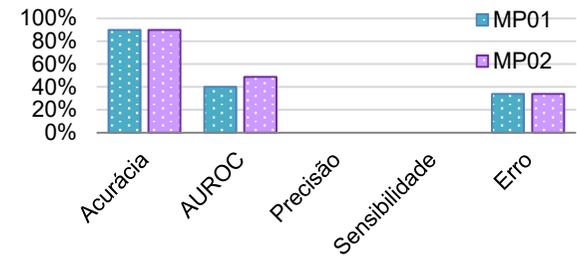
De qualquer forma, tal como indicado no item 4.1, os erros de validação e de teste indicam que ambos os modelos não atingiram o desempenho desejado, principalmente quando se observa que os menores erros de treinamento, validação e de teste estão entre a 0,2 e 0,5. Interpreta-se que esta limitação de desempenho está relacionada à quantidade de amostras e à baixa proporção de amostras da classe (1), que é 10% do total de amostras (Tabela 40 e Tabela 41).



(a) Treinamento

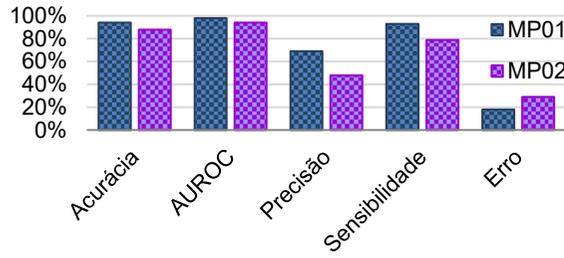


(b) Validação

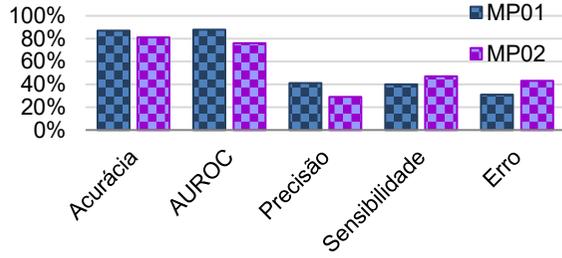


(c) Testes

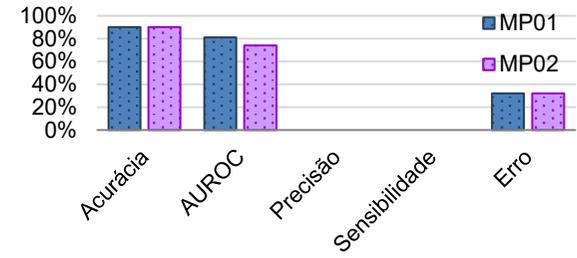
Figura 78 – Floresta Aleatória – Classes Desbalanceadas – Limiar Padrão - MP01 e MP02



(a) Treinamento

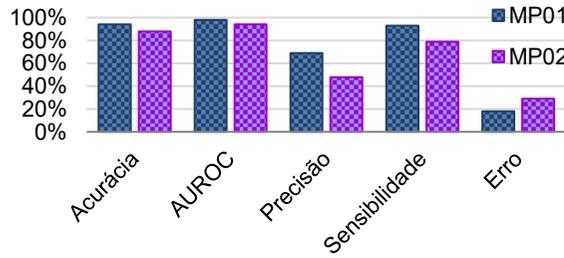


(b) Validação

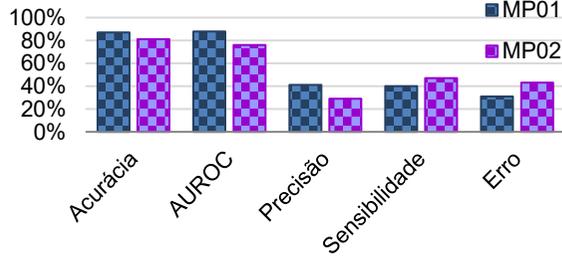


(c) Testes

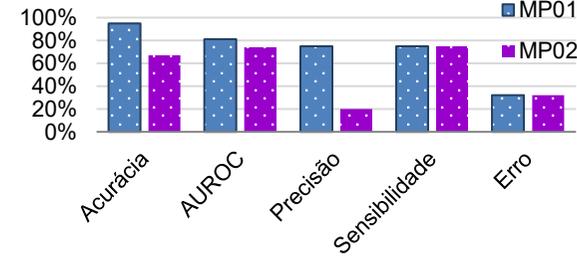
Figura 79 – Floresta Aleatória – Classes Balanceadas – Limiar Padrão - MP01 e MP02



(a) Treinamento



(b) Validação



(c) Testes

Figura 80 – Floresta Aleatória – Classes Balanceadas – Limiar Otimizado - MP01 e MP02

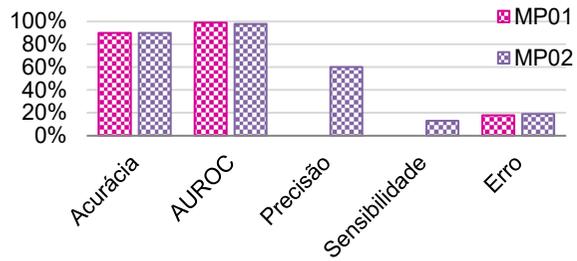
5.1.2 Máquina de Vetores-Suporte (Support Vector Machine - SVM)

Nas Figura 81 a Figura 83 estão compilados os resultados das métricas acurácia, *AUROC*, precisão e sensibilidade obtidos para os dois melhores modelos Máquina de Vetores-Suporte (*Support Vector Machine*), considerando-se as modulações MP01(Tabela 74, Tabela 53 e Tabela 54) e MP02 (Tabela 75, Tabela 56 e Tabela 57).

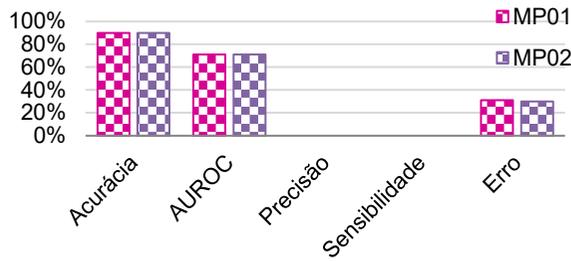
Os resultados para classes desbalanceadas (Figura 81), embora apresentados para fins de composição do quadro de resultados, não são considerados como referência devido sua resposta tendenciosa em favor da classe majoritária (APÊNDICE C).

Tratando-se de classes balanceadas, na Figura 82, pode-se observar que, no treinamento, na validação e no teste, MP01 e MP02 apresentam respostas similares, embora a *AUROC* e sensibilidade de validação da MP01 tenha sido superior à *AUROC* e sensibilidade de validação da MP02 iguais ou melhores resultados de desempenho do que os da MP02. Ademais, como a otimização de limiar foi realizada apenas na fase de teste, a Figura 83 (c) reflete mudanças das métricas e, de forma similar, seus resultados para a MP01 são melhores ou próximos aos resultados para a MP02. Sendo assim, comparando-se as respostas do modelo Floresta Aleatória MP01 com o modelo Floresta Aleatória MP02, entende-se que tanto os fatores adotados na MP01 quanto os utilizados na MP02, apresentam potencial equivalente

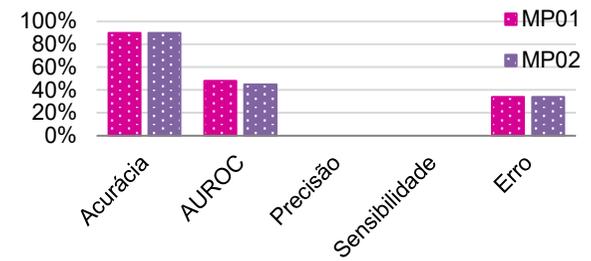
De qualquer forma, tal como indicado no item 4.2, os erros de validação e de teste indicam que ambos os modelos não atingiram o desempenho desejado, principalmente quando se observa que os menores erros de treinamento, validação e de teste estão entre a 0,2 e 0,4. Interpreta-se que esta limitação de desempenho está relacionada à quantidade de amostras e à baixa proporção de amostras da classe (1), que é 10% do total de amostras (Tabela 40 e Tabela 41).



(a) Treinamento

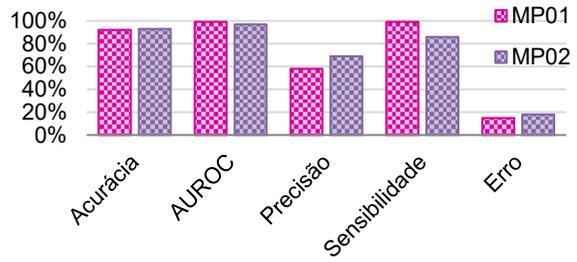


(b) Validação

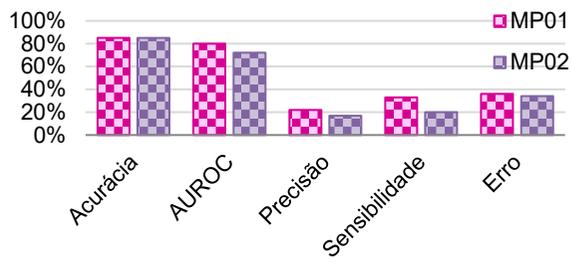


(c) Testes

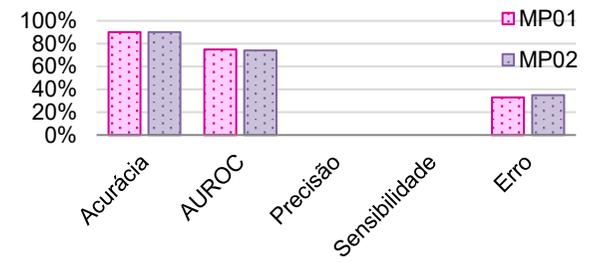
Figura 81 – Máquina de Vetores Suporte – Classes Desbalanceadas – Limiar Padrão - MP01 e MP02



(a) Treinamento

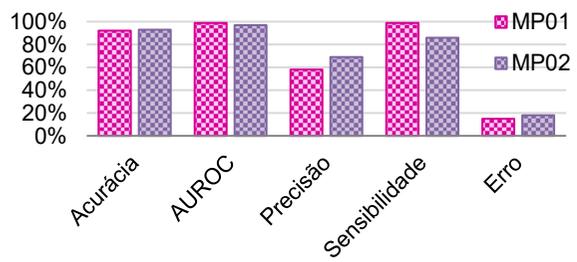


(b) Validação

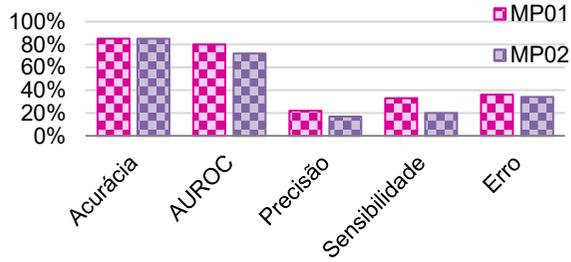


(c) Testes

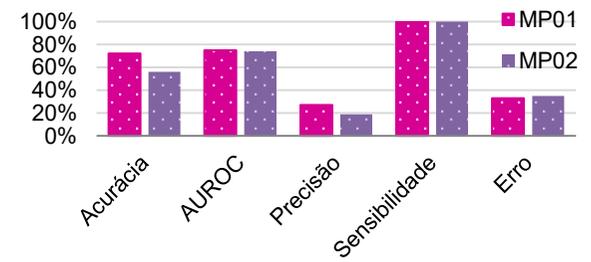
Figura 82 – Máquina de Vetores Suporte – Classes Balanceadas – Limiar Padrão - MP01 e MP02



(a) Treinamento



(b) Validação



(c) Testes

Figura 83 – Máquina de Vetores Suporte – Classes Balanceadas – Limiar Otimizado - MP01 e MP02

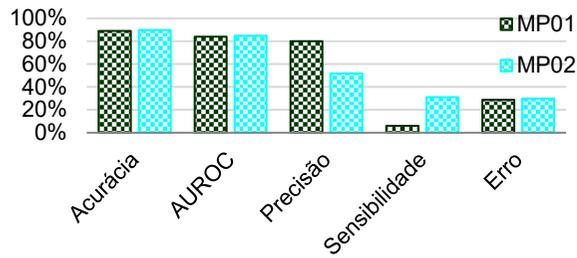
5.1.3 Perceptron Multicamadas (Multi-layer Perceptron - MLP)

Nas Figura 84 a Figura 86 estão compilados os resultados das métricas acurácia, *AUROC*, precisão e sensibilidade obtidos para os dois melhores modelos Perceptron Multicamadas (*Multi-layer Perceptron*), considerando-se as modulações MP01(Tabela 76, Tabela 59 e Tabela 60) e MP02 (Tabela 77, Tabela 62 e Tabela 63).

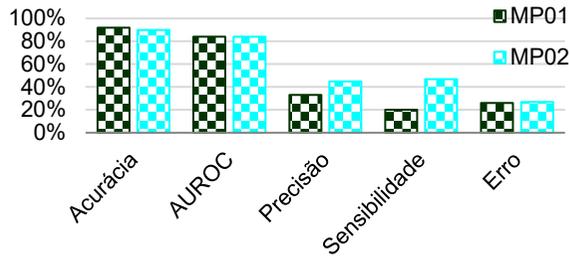
Os resultados para classes desbalanceadas (Figura 84), embora apresentados para fins de composição do quadro de resultados, não são considerados como referência devido sua resposta tendenciosa em favor da classe majoritária (APÊNDICE C).

Tratando-se de classes balanceadas, na Figura 85, pode-se observar que, no treinamento, na validação e no teste, as métricas da MP01 foram, em sua maioria, superiores ou iguais às da MP02, indicando melhor desempenho da MP01. Ademais, como a otimização de limiar foi realizada apenas na fase de teste, a Figura 86 (c) reflete mudanças das métricas e, de forma similar, seus resultados para a MP01 são melhores ou iguais aos resultados para a MP02. Sendo assim, comparando-se as respostas do modelo Perceptron Multicamadas MP01 com o modelo Perceptron Multicamadas MP02, entende-se que os fatores adotados na MP01 apresentam melhor potencial do que os utilizados na MP02

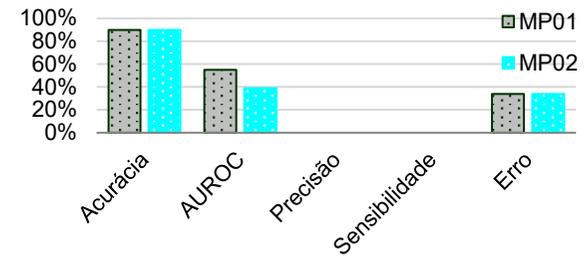
De qualquer forma, tal como indicado no item 4.3, os erros de validação e de teste indicam que ambos os modelos não atingiram o desempenho desejado, principalmente quando se observa que os menores erros de treinamento, validação e de teste estão entre 0,2 e 0,4. Interpreta-se que esta limitação de desempenho está relacionada à quantidade de amostras e à baixa proporção de amostras da classe (1), que é 10% do total de amostras (Tabela 40 e Tabela 41).



(a) Treinamento

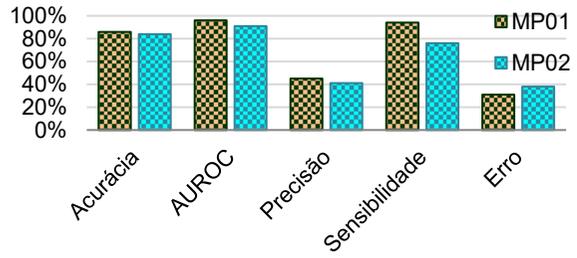


(b) Validação

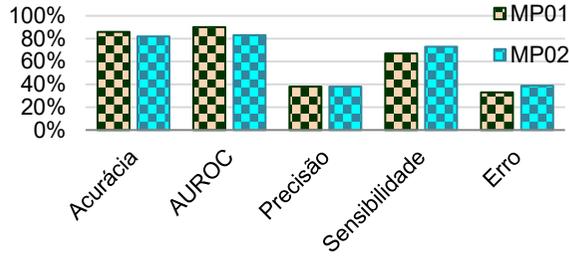


(c) Testes

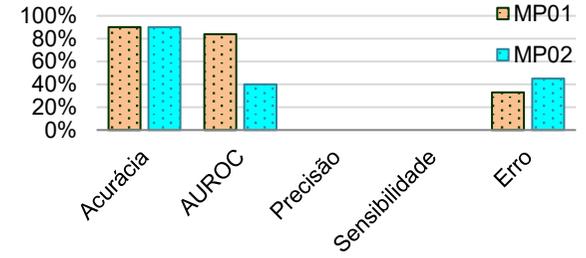
Figura 84 – Perceptron Multicamadas – Classe Desbalanceadas – Limiar Padrão - MP01 e MP02



(a) Treinamento

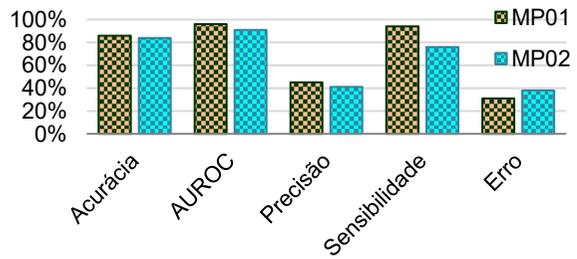


(b) Validação

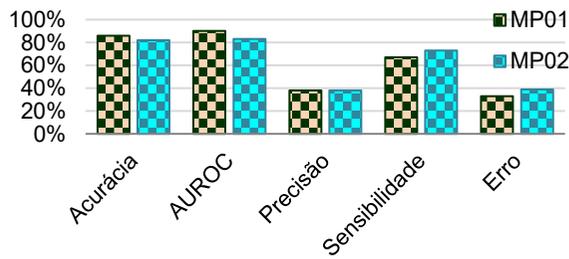


(c) Testes

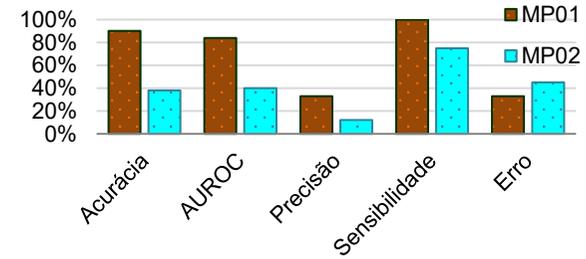
Figura 85 – Perceptron Multicamadas – Classe Balanceadas – Limiar Padrão - MP01 e MP02



(a) Treinamento



(b) Validação



(c) Testes

Figura 86 – Perceptron Multicamadas – Classe Balanceadas – Limiar Otimizado - MP01 e MP02

5.2 Modelos Classificadores

Os resultados das métricas dos modelos Floresta Aleatória (*Random Forest*), Máquina de Vetores-Suporte (*Support Vector Machine*) e Perceptron Multicamadas (*Multi-layer Perceptron*), conforme apresentado no item 4, seguem apresentados em formato gráfico para cada tipo de modulação de precipitação. Esta forma de agrupamento permite a comparação do desempenho entre modelos distintos de acordo com os fatores utilizados (MP01 e MP02) para treinamento, validação e teste.

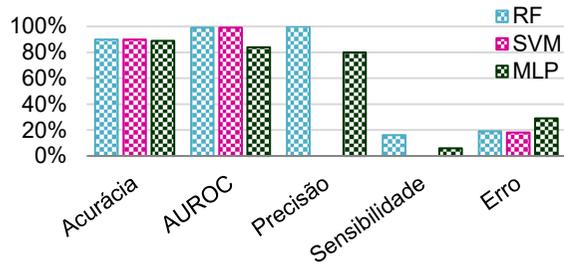
Os resultados para classes desbalanceadas, nas Figura 87 e Figura 90, embora apresentados para fins de composição do quadro de resultados, não são considerados como referência devido sua resposta tendenciosa em favor da classe majoritária (item 4.1 e APÊNDICE C), logo as análises comparativas apresentadas a seguir não abarcam os resultados com classes desbalanceadas.

5.2.1 Modulação de Precipitação MP01

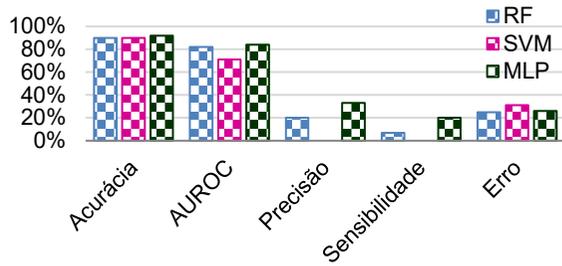
Considerando-se as métricas acurácia, *AUROC*, precisão e sensibilidade, nas Figura 87 a Figura 89 estão compilados os resultados da modulação MP01 dos melhores modelos Floresta Aleatória (item 4.1.1), Máquina de Vetores-Suporte (item 4.2.1) e Perceptron Multicamadas (item 4.3.1). Logo, a partir da apresentação conjunta dos resultados, pode-se verificar que:

- I. Os resultados das métricas de treinamento são, em sua maioria, superiores/melhores do que os resultados das métricas de validação, principalmente precisão e sensibilidade, embora os resultados da validação sejam próximos ao de treinamento.
- II. Os resultados das métricas de validação são, em sua maioria, superiores/melhores do que os resultados das métricas de teste. As métricas de teste representam a resposta do modelo em relação às amostras com as quais ele nunca teve contato e permitem a verificação do comportamento do modelo em relação à validação.
- III. Os resultados de acurácia, precisão e sensibilidade, em função da posição do limiar, estão sujeitos a variações. Os valores de precisão e sensibilidade para limiares otimizados são superiores aos valores com limiar padrão de 0,5, embora a modificação do limiar possa implicar na redução da acurácia;

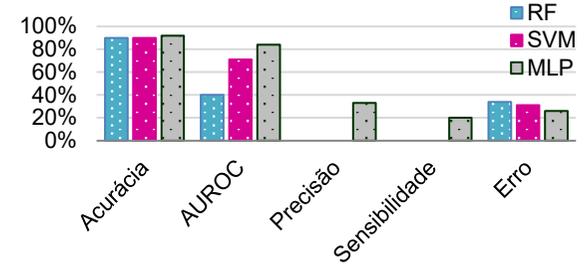
- IV. A *AUROC* de validação e de teste dos modelos Floresta Aleatória e Perceptron Multicamadas superam os resultados de *AUROC* do modelo Máquina de Vetores-Suporte. Também o erro de validação do modelo Máquina de Vetores-Suporte é maior do que o erro dos demais modelos. De modo geral, as maiores melhores métricas pertencem ao modelo Perceptron Multicamadas;
- V. Considerando-se as distribuições probabilísticas, o modelo Floresta Aleatória apresenta melhor distribuição do grupo de teste, com limiar otimizado em 0,125, enquanto no modelo Perceptron Multicamadas o limiar otimizado do grupo de teste está em 0,084. De qualquer forma, o esperado é que as distribuições do grupo de teste ocorram ao longo do intervalo [0 a 1] e que sejam semelhantes às do grupo de validação, algo que não aconteceu para nenhum modelo, visto que, para o limiar padrão de 0,5, nenhum modelo apresentou valores de precisão e sensibilidade;
- VI. Tomando-se a métrica *AUROC* de validação e de teste, o classificador Perceptron Multicamadas apresenta vantagem numérica ou resultado similar em relação ao modelo Floresta Aleatória. Enquanto Floresta Aleatória apresenta *AUROC* de 88% na validação e 81% no teste, Perceptron Multicamadas apresenta *AUROC* 90% na validação e 84% no teste. Entretanto o erro do Perceptron Multicamadas é 0,33 na validação e no teste, enquanto Floresta Aleatória apresenta erro de 0,31 na validação e 0,32 no teste;
- VII. Considerando-se o valor numérico da *AUROC*, o erro e a distribuição de probabilidade como indicadores de desempenho, entende-se que, para a modulação de precipitação MP01, o modelo Floresta Aleatória sinaliza maior potencial de resposta, visto que, embora a *AUROC* e erro sejam próximos ao do modelo Perceptron Multicamadas, a distribuição probabilística é melhor.



(d) Treinamento - Limar Padrão

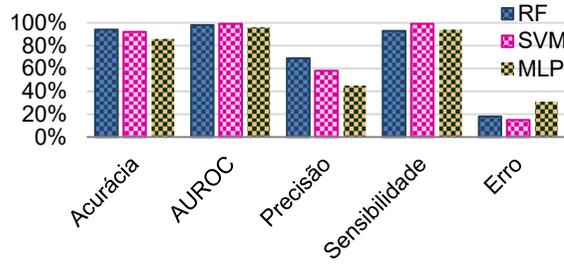


(e) Validação- Limar Padrão

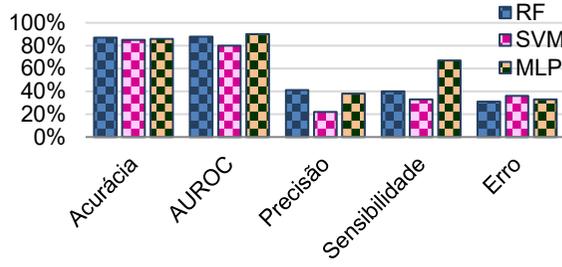


(f) Testes- Limar Padrão

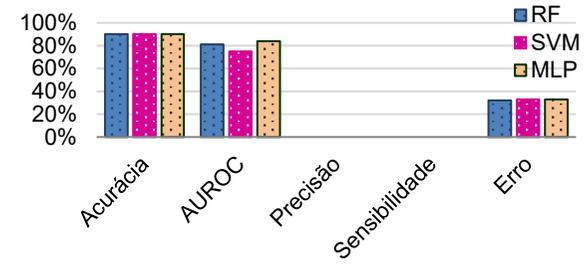
Figura 87 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Desbalanceadas – MP01



(d) Treinamento - Limar Padrão

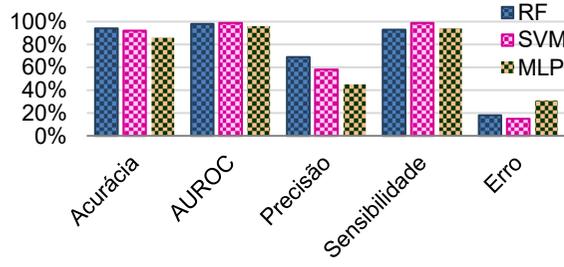


(e) Validação - Limar Padrão

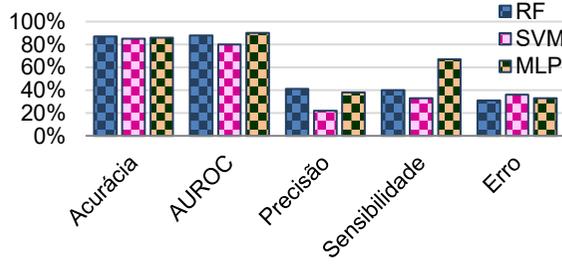


(f) Testes - Limar Padrão

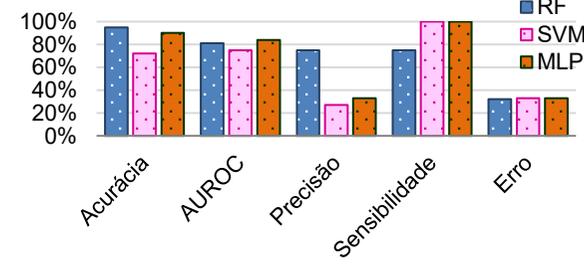
Figura 88 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Balanceadas – MP01



(d) Treinamento - Limar Otimizado



(e) Validação - Limar Otimizado



(f) Testes - Limar Otimizado

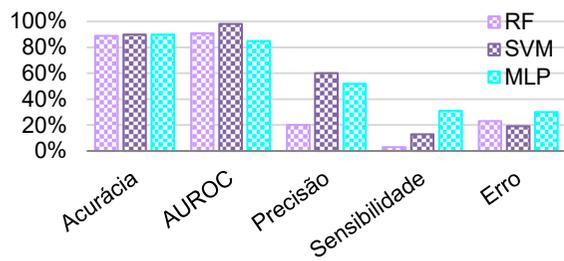
Figura 89 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Balanceadas – MP01

5.2.2 Modulação de Precipitação MP02

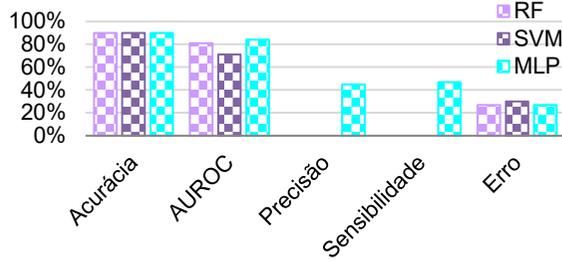
Considerando-se as métricas acurácia, *AUROC*, precisão e sensibilidade, nas Figura 90 a Figura 92, estão compilados os resultados da modulação MP02 dos melhores modelos Floresta Aleatória (item 4.1.2), Máquina de Vetores-Suporte (item 4.2.2) e Perceptron Multicamadas (item 4.3.2). Logo, a partir da apresentação conjunta dos resultados, pode-se verificar que:

- I. Os resultados das métricas de treinamento são, em sua maioria, superiores/melhores do que os resultados das métricas de validação, principalmente precisão e sensibilidade, embora os resultados da validação sejam próximos ao de treinamento.
- II. Os resultados das métricas de validação são, em sua maioria, superiores/melhores do que os resultados das métricas de teste, com exceção do erro de teste do modelo Floresta aleatória, que foi menor do que o erro de validação. As métricas de teste representam a resposta do modelo em relação às amostras com as quais ele nunca teve contato e permitem a verificação do comportamento do modelo em relação à validação.
- III. Os resultados de acurácia, precisão e sensibilidade, em função da posição do limiar, estão sujeitos a variações. Os valores de precisão e sensibilidade para limiares otimizados são superiores aos valores com limiar padrão de 0,5, embora a modificação do limiar possa implicar na redução da acurácia;
- IV. A *AUROC* e erro de validação dos modelos Floresta Aleatória e Perceptron Multicamadas superam os resultados de *AUROC* e erro do modelo Máquina de Vetores-Suporte. De modo geral, as maiores melhores métricas pertencem ao modelo Perceptron Multicamadas;

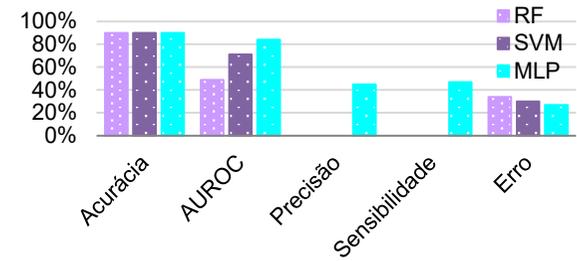
- V. Considerando-se as distribuições probabilísticas, o modelo Floresta Aleatória apresenta melhor distribuição do grupo de teste, com limiar otimizado em 0,301, enquanto no modelo Perceptron Multicamadas o limiar otimizado do grupo de teste está em 0,013. De qualquer forma, o esperado é que as distribuições do grupo de teste ocorram ao longo do intervalo [0 a 1] e que sejam semelhantes às do grupo de validação, algo que não aconteceu para nenhum modelo, visto que, para o limiar padrão de 0,5, nenhum modelo apresentou valores de precisão e sensibilidade;
- VI. Tomando-se a métrica *AUROC* de validação e de teste, o classificador Floresta Aleatória apresenta maior coerência entre resultados de validação e de teste em relação ao modelo Perceptron Multicamadas. Enquanto Floresta Aleatória apresenta *AUROC* de 76% na validação e 74% no teste, Perceptron Multicamadas apresenta *AUROC* 83% na validação e 40% no teste. Entretanto o erro do Floresta Aleatória é 0,43 na validação e 0,32 no teste, enquanto Perceptron Multicamadas apresenta erro de 0,39 na validação e 0,45 no teste;
- VII. Considerando-se o valor numérico da *AUROC*, o erro e a distribuição de probabilidade como indicadores de desempenho, entende-se que, para a modulação de precipitação MP02, o modelo Floresta Aleatória sinaliza maior potencial de resposta, visto que, embora o erro de validação seja maior do modelo Perceptron Multicamadas, além da distribuição probabilística ser melhor, o resultado de teste também foi superior.



(g) Treinamento - Limar Padrão

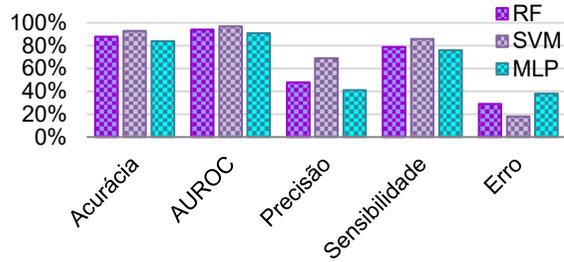


(h) Validação- Limar Padrão

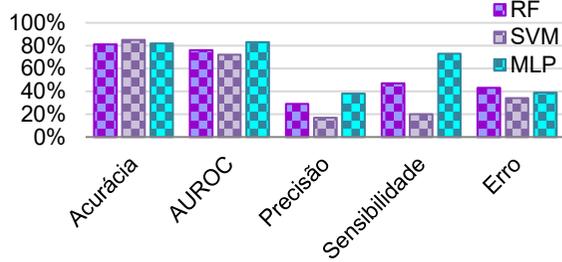


(i) Testes- Limar Padrão

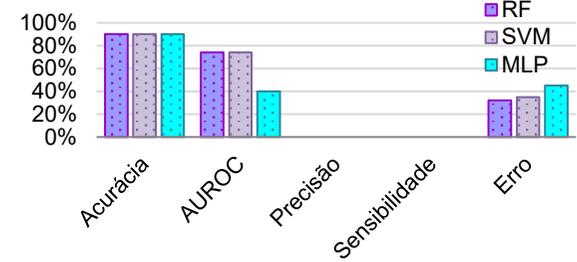
Figura 90 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Desbalanceadas – MP02



(g) Treinamento - Limar Padrão

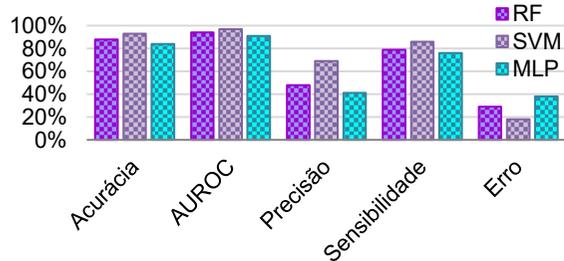


(h) Validação - Limar Padrão

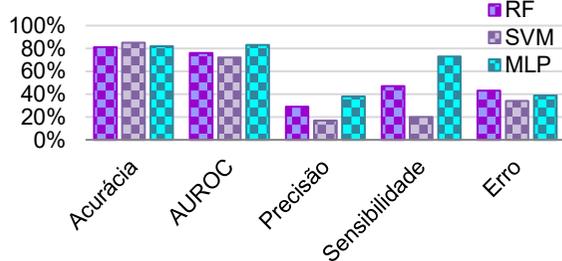


(i) Testes - Limar Padrão

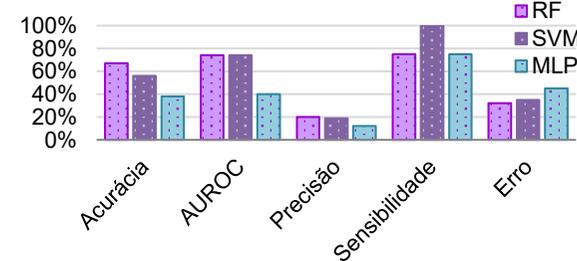
Figura 91 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Balanceadas – MP02



(g) Treinamento - Limar Otimizado



(h) Validação - Limar Otimizado



(i) Testes - Limar Otimizado

Figura 92 – Floresta Aleatória (RF), Máquina de Vetores-Suporte (SVM) Perceptron Multicamadas (MLP) – Classe Balanceadas – MP02

5.3 Análise Comparativa dos Resultados

Confrontando-se os resultados das análises dos itens 5.2.1 e 5.2.2, observa-se que o modelo Floresta Aleatória com modulação MP01 apresentou os melhores resultados.

Entretanto, tal como abordado no item 4.3, os erros de validação e de teste de todos os modelos indicam que eles não atingiram o desempenho desejado, principalmente quando se observa que os menores erros de treinamento, validação e de teste estão entre 0,2 e 0,4. Interpreta-se que esta limitação de desempenho está relacionada à quantidade de amostras e à baixa proporção de amostras da classe (1), que é 10% do total de amostras (Tabela 40 e Tabela 41).

5.4 Aplicação Do Modelo

A objetivo é que o modelo classificador realize a previsão de ocorrência de movimentos de massa a partir da classificação da precipitação em classe (0), sem ocorrência de movimento de massa, ou em classe (1), com ocorrência de movimento de massa. No item 3.5 é apresentada uma síntese de implementação do modelo.

Dentre os modelos estudados, o modelo classificador Floresta Aleatória, que utiliza a modulação de precipitação MP01, apresenta os melhores resultados de desempenho, conforme indicado no item 5.3. Sendo assim, para realização da previsão de ocorrência de movimento de massa, este modelo classificador será adotado.

5.4.1 Estrutura de Utilização do Modelo

Para fins de caracterização da forma de uso do modelo, apresenta-se a seguir um exemplo de aplicação relativo a eventos de precipitação, com ocorrência de movimento de massa, que acontecerem no ano de 2017. Ressalta-se que os dados de entrada utilizados para treinamento, validação e teste do modelo pertencem ao período de 2009 a 2015. Deste modo, os dados de 2017 são inéditos para o modelo.

Para uso do modelo, são necessárias as definições das acumuladas e das durações dos 4 (quatro) intervalos caracterizadores das 96h anteriores ao evento (Figura 62). Ainda é importante lembrar que se utiliza a precipitação média das estações da área/região considerada. Deste modo, deve-se extrair de cada estação, da região de interesse, a precipitação acumulada e duração para cada intervalo e, a partir destes dados, calcular a precipitação acumulada média e duração média.

Por fim, na Tabela 64 estão detalhados os dados de entrada referentes às datas e horários em que se deseja realizar a classificação do evento de precipitação enfrentado. Considerando-se as limitações de resultados do modelo (item 4.1.1.2), adota-se o limiar otimizado estipulado pelos dados de teste (Tabela 45). Sendo assim, o modelo classificou o evento de precipitação em classe (1) a partir das 20:30h do dia 20/06/2017 até às 19:00h do dia 21/06/2017, conforme Figura 93 e Tabela 65. Neste intervalo temporal, alguns veículos de comunicação, tal como Ramalho (2017), sinalizaram a ocorrência de movimento de massa no dia 21/06/2017.

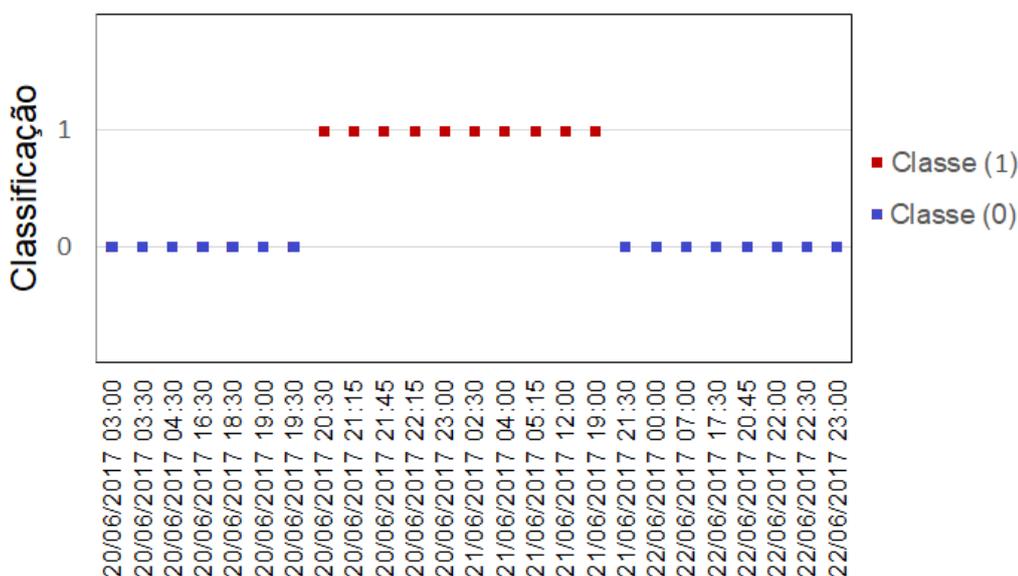


Figura 93 – Floresta Aleatória (MP01): Exemplo de Aplicação do Modelo

A partir da forma de aplicação proposta, é possível perceber que modelos desta natureza podem contribuir para a tomada de decisão de evacuação de áreas de risco, inclusive em tempo real. Além disto, o uso destes modelos pode ser relativamente simples e automatizado por meio de rotinas/códigos.

A aplicação do modelo requer o estabelecimento da composição dos 1º a 4º intervalos e suas durações, tal como efetuado na Tabela 64, e a partir destes dados é possível extrair a predição de classificação do evento de precipitação analisado.

Tabela 64. Exemplo de Classificação – Dados Entrada de Estação Média

| Referência | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | |
|------------|----------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|
| Data | Horário | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) |
| 20/06/2017 | 03:00:00 | 26 | 2 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 03:30:00 | 38 | 3 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 04:30:00 | 45 | 3 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 16:30:00 | 55 | 4 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 18:30:00 | 67 | 5 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 19:00:00 | 77 | 6 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 19:30:00 | 87 | 6 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 20:30:00 | 95 | 7 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 21:15:00 | 104 | 8 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 21:45:00 | 118 | 8 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 22:15:00 | 128 | 9 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20/06/2017 | 23:00:00 | 138 | 10 | 0 | 0 | 0 | 0 | 0 | 0 |
| 21/06/2017 | 02:30:00 | 127 | 10 | 16 | 2 | 0 | 0 | 0 | 0 |
| 21/06/2017 | 04:00:00 | 107 | 9 | 43 | 3 | 0 | 0 | 0 | 0 |

| Referência | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | |
|------------|----------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|
| Data | Horário | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) |
| 21/06/2017 | 05:15:00 | 114 | 10 | 45 | 4 | 0 | 0 | 0 | 0 |
| 21/06/2017 | 12:00:00 | 122 | 14 | 45 | 4 | 0 | 0 | 0 | 0 |
| 21/06/2017 | 19:00:00 | 90 | 12 | 77 | 6 | 0 | 0 | 0 | 0 |
| 21/06/2017 | 21:30:00 | 58 | 9 | 110 | 8 | 0 | 0 | 0 | 0 |
| 22/06/2017 | 00:00:00 | 39 | 8 | 135 | 10 | 7 | 1 | 0 | 0 |
| 22/06/2017 | 07:00:00 | 24 | 6 | 117 | 11 | 45 | 4 | 0 | 0 |
| 22/06/2017 | 17:30:00 | 19 | 3 | 111 | 13 | 56 | 5 | 0 | 0 |
| 22/06/2017 | 20:45:00 | 19 | 3 | 70 | 10 | 97 | 8 | 0 | 0 |
| 22/06/2017 | 22:00:00 | 19 | 3 | 44 | 9 | 124 | 9 | 0 | 0 |
| 22/06/2017 | 22:30:00 | 18 | 3 | 36 | 8 | 132 | 9 | 0 | 0 |
| 22/06/2017 | 23:00:00 | 12 | 2 | 36 | 8 | 138 | 10 | 0 | 0 |

Tabela 65. Exemplo – Resultado do Modelo Classificador

| Referência | | | Referência | | | Referência | | |
|------------|----------|--------|------------|----------|--------|------------|----------|--------|
| Data | Horário | Classe | Data | Horário | Classe | Data | Horário | Classe |
| 20/06/2017 | 03:00:00 | 0 | 20/06/2017 | 21:45:00 | 1 | 22/06/2017 | 00:00:00 | 0 |
| 20/06/2017 | 03:30:00 | 0 | 20/06/2017 | 22:15:00 | 1 | 22/06/2017 | 07:00:00 | 0 |
| 20/06/2017 | 04:30:00 | 0 | 20/06/2017 | 23:00:00 | 1 | 22/06/2017 | 17:30:00 | 0 |
| 20/06/2017 | 16:30:00 | 0 | 21/06/2017 | 02:30:00 | 1 | 22/06/2017 | 20:45:00 | 0 |
| 20/06/2017 | 18:30:00 | 0 | 21/06/2017 | 04:00:00 | 1 | 22/06/2017 | 22:00:00 | 0 |
| 20/06/2017 | 19:00:00 | 0 | 21/06/2017 | 05:15:00 | 1 | 22/06/2017 | 22:30:00 | 0 |
| 20/06/2017 | 19:30:00 | 0 | 21/06/2017 | 12:00:00 | 1 | 22/06/2017 | 23:00:00 | 0 |
| 20/06/2017 | 20:30:00 | 1 | 21/06/2017 | 19:00:00 | 1 | | | |
| 20/06/2017 | 21:15:00 | 1 | 21/06/2017 | 21:30:00 | 0 | | | |

5.4.2 Utilização do Modelo com Previsão Meteorológica

É possível utilizar este modelo para realizar, com antecipação, a previsão de ocorrência de movimentos de massa. Neste caso, pode-se compor os intervalos caracterizadores das 96h com informações originadas da previsão meteorológica, além daquelas originadas das estações pluviométricas (item 5.4.2).

Em cada intervalo, a precipitação é caracterizada por 2 (dois) atributos, acumuladas 24h (mm) e duração da precipitação (h). Conforme apresentado na Figura 94, o 1º. Intervalo corresponde às 24h em que se almeja realizar a previsão do movimento de massa, enquanto os 2ª a 4º intervalos representam as 72h antecedentes.

Por exemplo, no tempo t_0 (Figura 94) pode-se averiguar a classificação da precipitação ocorrida nas últimas 96h e verificar se a previsão do modelo é classe (1), em que existe previsão de ocorrência de movimento de massa, ou é classe (0), em que não há previsão de ocorrência de movimento de massa.

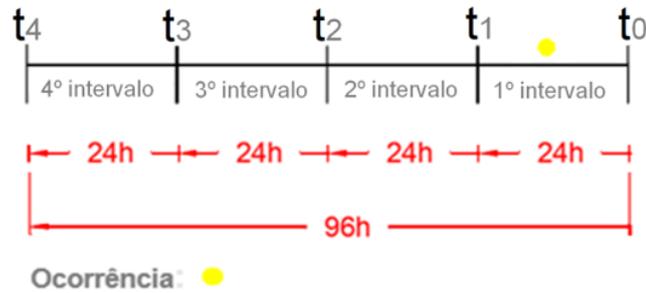


Figura 94 – Estrutura de Aplicação do Modelo

Esta averiguação pode ocorrer em tempo real, e ser atualizada à medida que ocorre a disponibilização dos registros de captação das estações pluviométricas no sistema Alerta Rio. Entretanto, como a previsão ocorre a partir da precipitação captada no momento t_0 , neste formato de acompanhamento não haveria tempo hábil para realizar a evacuação da área.

Uma forma de incorporar a antecipação, de modo que se possa realizar a evacuação da área antes da ocorrência do movimento, seria utilizar a previsão meteorológica. Neste cenário, com objetivo de realizar a previsão sobre a ocorrência de movimento de massa num intervalo temporal futuro, pode-se adotar o tempo de referência (t_r). Nesta situação, o 1º intervalo é composto pelo intervalo temporal futuro, que transcorre de t_0 a t_r , e, também, pelo intervalo temporal passado, mas recente, que transcorre de t_r a t_1 (Figura 95).

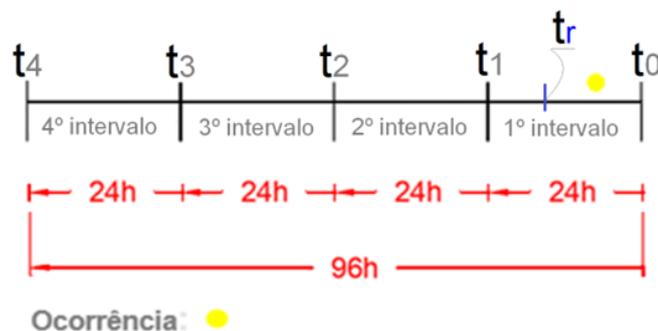


Figura 95 – Estrutura para Aplicação do Modelo – Intervalo Futuro

Na Tabela 66, tem-se a indicação da composição dos 4 (quatro) intervalos para uma situação hipotética, em que se deseja realizar a previsão de ocorrência de movimento de massa para as próximas 4 horas, ou seja, em um intervalo temporal futuro.

Uma vez que o modelo foi treinado a partir de modulações de precipitação cujo 1º intervalo é composto por 24h, é possível que ele seja composto pelo somatório de duas parcelas intervalo 1º (a) e intervalo 1º (b).

Tabela 66. Aplicação do Modelo - Dados de Entrada – Intervalo Futuro

| 1º Intervalo (0-24h) | | | | 2º Intervalo Registro Pluviométrico (24-48h) | | 3º Intervalo Registro Pluviométrico (48-72h) | | 4º Intervalo Registro Pluviométrico (72-96h) | |
|---|----------------|---|----------------|---|----------------|---|----------------|---|----------------|
| Previsão Meteorológica Intervalo 1º (a) T0 a Tr | | Registro Pluviométrico Intervalo 1º (b) Tr a T1 | | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) |
| Acumulada (mm/4h) | Duração (h) | Acumulada (mm/20h) | Duração (h) | | | | | | |
| | | | | | | | | | |

A partir da composição dos 1º a 4º intervalos (Tabela 66), para obtenção da classificação da precipita-se, prossegue-se com a estrutura de utilização do modelo, tal como apresentada no item 5.4.1.

6 CONSIDERAÇÕES FINAIS

Este trabalho se dedicou a desenvolver pesquisa que conduzisse a um modelo de classificação que toma, como dados de entrada, atributos de mesma natureza que os utilizados no sistema de Alerta Rio. O funcionamento deste sistema foi analisado em 2015 e recomendações para sua melhoria foram apresentadas, principalmente em termos de redução dos falsos-positivos (item 1.2.4.1).

Desta forma, considerando-se as limitações de tipo, de quantidade e de confiabilidade dos dados disponíveis para implantação e funcionamento do sistema Alerta Rio, entendeu-se pertinente que os modelos desenvolvidos nesta pesquisa tivessem limitações equivalentes. Entretanto, apesar da equivalência em termos de condicionantes, foram utilizadas metodologia e abordagem de análise diferentes da utilizada pelo sistema de alerta em operação na cidade Rio de Janeiro.

A manutenção das mesmas limitações, em combinação com a introdução de metodologia e abordagem diferentes, mantém um grau de similaridade com o sistema Alerta Rio e conduz à extração de conclusões em relação ao banco de dados existente e, também, aos métodos gráficos em comparação com métodos de aprendizado de máquina.

A seguir, tem-se um resumo dos pontos principais da metodologia e da abordagem utilizadas nesta pesquisa.

Quanto à metodologia, foram realizadas:

- Redução da zona de alerta, tomando-se um conjunto específico de bacias de drenagem, em função da quantidade de dados disponíveis para análise (item 3.1);
- Utilização da Estação Média como forma simplificada de consideração da precipitação na área de estudo. A análise estatística preliminar (item 3.3) conduziu ao entendimento de que a Estação Média pode ser conservadora quando comparada com alguma das estações tomadas individualmente;
- Adoção de 2 (dois) tipos de modulação da precipitação, que incorporam 96h a partir da data de ocorrência do movimento de massa (item 3.4.1).

Em relação à abordagem de análise:

- Realização de análise estatística preliminar (item 3.3), a qual conduziu à observação de que, em termos de magnitude de acumulada diária (mm),

os eventos de precipitação relacionados à deflagração de movimentos são provenientes do grupo de valores atípicos/discrepantes (Figura 53);

- Adoção de técnica de aprendizado de máquina (item 3.5) para desenvolvimento de modelo de classificador, o qual classifica eventos de precipitação em classe (0), sem ocorrência de movimento de massa, ou em classe (1), com ocorrência de movimento de massa.

De modo geral, o objetivo dos modelos de aprendizado de máquina é permitir que a partir das informações de altura e de duração de precipitação, as quais podem ser extraídas em tempo real do sistema Alerta Rio, seja possível realizar a classificação do evento de precipitação e, conseqüentemente a previsão de ocorrência ou de não ocorrência de movimentos de massa. Como a disponibilização do registro de altura de precipitação ocorre a cada 15 minutos, pode-se, a cada 15 minutos, verificar a resposta do modelo para o evento de precipitação que se enfrenta (item 5.4).

Entretanto, para fins de evacuação das áreas de risco é necessário prever antecipadamente a magnitude da precipitação ou a taxa de precipitação no tempo.

Neste caso, pode-se tomar partido da previsão meteorológica (item 5.4.2) e, a partir dos dados meteorológicos, utilizar o modelo para previsão de ocorrência ou de não ocorrência de movimento de massa para a região a qual os modelos foram construídos.

6.1 Conclusões

Dentre os três classificadores adotados (item 4), os modelos classificadores originados dos algoritmos Floresta Aleatória (*Random Forest*) e Perceptron Multicamadas (*Multi-layer Perceptron*) indicam que o uso de técnicas de aprendizado de máquina é aplicável e pode contribuir para tomada de decisão, mesmo quando considerados apenas eventos de precipitação como fator indicativo para previsão de ocorrência de movimentos de massa.

Modelos baseados em técnicas de aprendizado de máquina possuem natureza probabilística, a qual está implícita na estrutura dos algoritmos. As métricas de avaliação do desempenho do modelo evidenciam esta natureza probabilística. A matriz de confusão, por exemplo, permite transparecer as incertezas do modelo, principalmente, por meio das taxas de falsos-positivos e de falsos-negativos (item 4).

Especificamente no caso estudado, com dados de entrada pertencentes ao período de 2009 a 2015, os resultados das métricas do melhor modelo, principalmente quando se observa a matriz de confusão do grupo de teste (Figura 67) replicam, embora em menor grau, a quantidade de falsos-positivos em relação ao sistema operacional do Alerta Rio (item 1.2.4.1). Este é um dos fatores indicativos de que ainda resta necessária maior evolução do modelo proposto.

Sendo assim, a partir da observação de respostas similares entre o melhor modelo (item 5.2) e o sistema operacional atual, destacam-se 2 (duas) possibilidades:

- P01) Modelos fundamentados em técnicas de aprendizado de máquina, que considerem apenas precipitação como fator, cujos resultados apresentam redução das taxas de falsos-positivos e de falsos-negativos, dependem da ampliação do conjunto de amostras;
- P02) Além da ampliação do conjunto de amostras, pode ser necessário adicionar outros atributos, pois apenas atributos caracterizadores de precipitação possivelmente não resultarão em aumento da precisão e/ou da sensibilidade do modelo.

A realização da primeira possibilidade (P01) implica necessariamente no incremento de amostras/exemplares e caso, após o incremento de amostras não se observar a melhoria do modelo, entende-se razoável colocar em prática a possibilidade P02.

Em relação à P02, o desafio está na escolha dos atributos que podem apoiar na evolução de resposta do modelo e as limitações estão na existência de tais informações em quantidade e qualidade suficientes para nutrir o modelo.

Desta forma, tem-se que ambas as possibilidades (P01 e P02) permitiriam melhorar modelos baseados em técnicas de aprendizado de máquina. No caso em questão, mais dados relacionados a movimentos de massa, com maior precisão de data e localização das ocorrências, poderiam resultar em evolução dos modelos.

Fato é que a evolução de análise de estabilidade em escala regional, tomando-se partido de ferramentas computacionais disponíveis, está diretamente relacionada à produção e gerenciamento de dados confiáveis e diversos. A expectativa é que a produção de dados permita o desenvolvimento de modelos com menores erros e maiores precisão e sensibilidade do que as geradas pelo melhor modelo desta tese.

Entretanto, mesmo partindo-se do entendimento de que modelos classificadores fundamentados em Floresta Aleatória (*Random Forest*) e Perceptron Multicamadas (*Multi-layer Perceptron*) são passíveis de aperfeiçoamento, sugere-se que eles sejam utilizados conjuntamente com o sistema operacional do Alerta Rio, não necessariamente como referência para tomada de decisão, mas como complemento de informação, visto que ofertam resposta diferenciada em relação à área de estudo piloto.

De qualquer forma, pontua-se que para esta pesquisa, a realização de análise comparativa encontrou a limitação de que o critério do Alerta Rio adota categorias como referência, podendo ser classificado como qualitativo, enquanto análises probabilísticas respondem quantitativamente. Neste cenário, é necessário estabelecer uma relação de correspondência entre ambas as formas de resposta, para que se possa verificar comparativamente aspectos de convergência e de divergência entre o modelo gráfico e a análise estatística.

A utilização conjunta de ambos os modelos pode promover seus desenvolvimentos e evolução, uma vez que permitirá quantificar, avaliar e comparar ambas as respostas e possivelmente extrair pontos de melhorias além dos que foram observados nesta tese.

Ainda, cabe ressaltar que, no caso das relações precipitação vs movimento de massa, o sistema é natural, dinâmico e sujeito a mudanças (físicas, climáticas etc.). Desta forma, de tempos em tempos, as análises devem ser refeitas incorporando-se dados que reflitam as transformações mais recentes.

6.2 Discussões

Especificamente em relação a ampliação do conjunto de amostras (P02), uma boa diretriz seria aproveitar os projetos desenvolvidos pelo Centro Nacional de Monitoramento e Alertas de Desastres Naturais – CEMADEM (2014, 2019), que com o intuito de aperfeiçoar os estudos relacionados à estabilidade de encostas e consequentemente as inferências sobre a ocorrência de movimentos de massa, possui projetos de implantação de estações que monitoram a evolução da umidade nas camadas de solo juntamente com a captação de precipitação.

Neste sentido, os Projetos de Monitoramento Geodinâmico de encostas, que realizam o acompanhamento, em tempo real, de deslocamento, de precipitação e de umidade do solo por meio de Estações Totais Robotizadas (ETR) no Município de

Campos do Jordão (CEMADEM,2014) ou que monitora, por meio de Plataformas de Coleta de Dados Geotécnicos – PCDs GEO, encostas da Baixada Santista em termos de evolução da frente de saturação até 3,0 m de profundidade podem ser adotados como fontes de dados.

Estes projetos demonstram uma propensão de se incorporar aos sistemas existentes ferramentas capazes de melhor caracterizar atributos envolvidos nos fenômenos naturais e representam desenvolvimento de políticas públicas que permitirá evolução de pesquisas relacionadas à estabilidade de encostas para escala regional. Ademais, também nos trabalhos de Mirus *et al.* (2018), Wicki *et al.* (2020) e Guzzetti *et al.*(2020), pode-se observar uma tendência de análise conjunta de medidas de precipitação e de umidade do solo para melhoria da eficiência dos sistemas de alerta, em Mirus *et al.* (2018), Wicki *et al.* (2020) são indicadas explicitamente a redução das taxas de falsos-positivos e de falsos-negativos.

Esta pesquisa reforça a fragilidade das bases de dados atuais e sinaliza a necessidade de evolução dos sistemas de coleta, registro e gerenciamento de dados, que permitirão desenvolver o histórico e melhorar as análises.

Entretanto, no caso da cidade do Rio de Janeiro, a redução dos dados de movimentos de massa pode significar que a cidade está mais resiliente a estes fenômenos.

Por fim, tratando-se do tópico “Técnicas de Aprendizado de Máquina – Classificação” as pesquisas da revisão bibliográfica permitiram algumas observações em relação às métricas de avaliação de desempenho. Logo, seguem algumas pontuações respeito deste tema:

- A adoção generalizada da acurácia como métrica aferidora da capacidade preditiva de modelos pode conduzir a interpretações equivocadas e otimistas sobre a capacidade preditiva do modelo. A apresentação do resultado das métricas para modelos desbalanceados (item 4.1 e APÊNDICE C) se propuseram a evidenciar que alta acurácia nem sempre significa um bom modelo;
- A utilização de uma combinação de métricas (item 2.4.2), embora trabalhosa, conduz a uma melhor interpretação sobre a capacidade do modelo. A métrica erro (log-loss), por exemplo, reflete aspectos de distribuição probabilística, embora seja considerada rigorosa por penalizar fortemente distribuições assimétricas. A *AUROC* ou curva

ROC conduzem ao entendimento de que pode existir algum limiar (Figura 65) em que as classes melhor se diferenciam, mesmo que o desempenho do modelo não esteja bom, com alto erro;

- A adoção do limiar padrão em 0,5 para segregação de classes, no caso binário, pode ser entendido como algo opcional. É possível que o modelo responda melhor com um limiar em 0,4, ou 0,6, por exemplo. Neste caso, entende-se que é aceito certo grau de análise subjetiva por parte do desenvolvedor do modelo, ao ponderar os prós e contras da mudança de limiar, e conseqüentemente da métrica que será priorizada, precisão ou sensibilidade.

6.3 Sugestões Para Pesquisas Futuras

Realizar o desenvolvimento de modelos:

- i) Que tomem como dados de entrada acumuladas das estações pluviométricas, individualmente ou em conjunto, para fins de comparação da evolução da resposta do modelo que adota a Estação Média;
- ii) Que consideram a precipitação antecedente, mas que a caracterizam de forma distinta, seja por meio da umidade do solo, seja por meio da precipitação, ou até utilizando ambas as formas conjuntamente;
- iii) Multiclasse, cuja distinção das classes se fundamenta na severidade da precipitação, ou seja, na quantidade de movimentos de massa causados pelos eventos de precipitação considerados;
- iv) A partir da inserção de atributos topográficos, geomorfológicos, ambientais, dentre outros, entretanto deve-se atentar para as implicações de se utilizar, conjuntamente, atributos que transcorrem no tempo com atributos que caracterizam o espaço físico. A adoção de atributos vinculados ao espaço físico requer maior cuidado no tratamento dos dados, pois é necessário vincular a ocorrência no espaço físico com a situação temporal observada (precipitação);
- v) A partir da expansão do conjunto de dados para treinamento, validação e testes. Expansão relacionada ao período de coleta dos dados, ou relacionada à região de abrangência, ampliando-se a área de estudo além das fronteiras delimitadas para a região de estudo piloto;

- vi) Para demais regiões da cidade do Rio de Janeiro, em continuidade ao realizado para a região de estudo piloto, com a finalidade de abranger/cobrir todas as zonas de alerta do Sistema Alerta Rio;
- vii) Para outras regiões, em outros Municípios, Estados, Países, caso elas possuam banco de dados disponíveis para uso. Uma opção seria conversar com o CEMADEM e verificar se existe banco de dados de precipitação e umidade de solo disponível para acesso e desenvolvimento de pesquisas acadêmicas;

REFERÊNCIAS

ABDULKAREEM, N. M.; ABDULAZEEZ, A. M. (2021). **Machine Learning Classification Based on Radom Forest Algorithm: A Review**. International Journal of Science and Business, v. 5, n. 2, p. 128–142. DOI: 10.5281/zenodo.4471118.

ABRAHAM, M.T., POTHURAJU, D., SATYAM, N. (2019). **Rainfall thresholds for prediction of landslides in Idukki, India: an empirical approach**. Water 11, 2113. <https://doi.org/10.3390/w11102113>.

ACHU, A. L.; THOMAS, J.; AJU, C. D.; REMANI, P. K.; GOPINATH, G. (2022). **Performance evaluation of machine learning and statistical techniques for modelling landslide susceptibility with limited field data**. Earth Science Informatics, v. 2020, p. 1025–1039. DOI: 10.1007/s12145-022-00910-8.

ADVINCULA, M.R.E. (2016) **Avaliação do Efeito de Aumento de Poropressão nas Características de Resistência de Três Solos Tropicais**. Tese de Doutorado, PUC-RIO, Rio de Janeiro, RJ, 278 p.

ALBUQUERQUE, S.N. (2019). **Elaboração de mapa de susceptibilidade ao risco geotécnico no Maciço da Tijuca com utilização de modelo probabilístico**. Dissertação de Mestrado, PGECIV, UERJ, Rio de Janeiro, RJ, 140 p.

ALERTA RIO. **Sistema Alerta Rio da Prefeitura do Rio de Janeiro**. Disponível em: <http://AlertaRio.rio.rj.gov.br/> . Acesso em: 16 de agosto de 2021.

AL-NAJJAR, A. H.; PRADHAN, B.; SARKAR, R.; BEYDOUN, G.; ALAMRI, A. (2021). **A new integrated approach for landslide data balancing and spatial prediction based on generative adversarial networks**. Remote Sensing, v. 13, n. 19. DOI: 10.3390/rs13194011.

ALPAYDIN, E. (2014). **Introduction to Machine Learning**. MIT Press. 3rd edition.

ALVIOLI, M.; GUZZETTI, F.; ROSSI, M. (2014). **Scaling properties of rainfall induced landslides predicted by a physically based model**. Geomorphology, v. 213, p. 38–47. DOI: 10.1016/j.geomorph.2013.12.039.

BAO, H.; ZENG, C.; PENG, Y.; WU, S. (2022). **The use of digital technologies for landslide disaster risk research and disaster risk management: progress and prospects**. *Environmental Earth Sciences*, v. 81, n. 18, p. 1–18. DOI: 10.1007/s12665-022-10575-7.

BERTI, M., MARTINA, M. L. V., FRANCESCHINI, S., PIGNONE, S., SIMONI, A. AND PIZZIOLO, M. (2012) **Probabilistic rainfall thresholds for landslide occurrence using Bayesian approach**. *Journal of Geophysical research*, Vol 117, F04006, doi:10.1029/2012JF002367.

BISPO, P. C.; DE ALMEIDA, C. M.; VALERIANO, M. M.; DE MEDEIROS, J. S.; CREPANI, E. (2011). **Análise da suscetibilidade aos movimentos de massa em são sebastião (SP) com o uso de métodos de inferência espacial**. *Geociencias*, v. 30, n. 3, p. 467–478.

BORDONI, M.; BITTELLI, M.; VALENTINO, R.; CHERSICH, S.; PERSICHILLO, M. G.; MEISINA, C. (2018). **Soil Water Content Estimated by Support Vector Machine for the Assessment of Shallow Landslides Triggering: the Role of Antecedent Meteorological Conditions**. *Environmental Modeling and Assessment*, v. 23, n. 4, p. 333–352. DOI: 10.1007/s10666-017-9586-y.

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, UnB, Brasília, DF.

BRAND, E. W., PREMCHITT, J. and PHILIPSON, H.B. (1984) **Relationship between rainfall and landslides in Hong Kong**. *Proceedings of the Fourth International Symposium on Landslides*, Toronto, vol. 1, pp 377-384.

BROWNLEE, J. (2020). **A Gentle Introduction to Threshold-Moving for Imbalanced Classification**. Disponível em: <https://machinelearningmastery.com/threshold-moving-for-imbalanced-classification/>. Acesso em: 27 de fevereiro de 2023.

BRUNETTI, M. T., S. PERUCCACCI, M. ROSSI, S. LUCIANI, D. VALIGI, and F. GUZZETTI (2010) **Rainfall thresholds for the possible occurrence of landslides in Italy**, Nat. Hazards Earth Syst. Sci., 10, 447–458, doi:10.5194/nhess-10-447-2010.

CALVELLO, M., D'ORSI, R. N., PICIULLO, L., PAES, N., MAGALHAES, M., LACERDA, W. A. (2015) **The Rio de Janeiro early warning system for rainfall-induced landslides: Analysis of performance for the years 2010-2013**, International Journal of Disaster Risk Reduction

CARNEIRO, R. F. (2019) **Adensamento unidimensional com fluxo radial considerando a viscosidade dos solos e a compressão secundária**. Tese de Doutorado em Geotecnia, UERJ, Rio de Janeiro, RJ.

CEMADEM (2014). **Sensores Geotécnicos para Monitoramento de Deslizamentos**. Ministério da Ciência, Tecnologia, Inovações e Comunicações. Disponível em: <http://www2.cemaden.gov.br/sensores-geotecnicos/>. Acesso em: 28 de março de 2023.

CEMADEM (2019). **RedeGeo e informações sobre umidade de solo das encostas para prevenção de deslizamentos**. Ministério da Ciência, Tecnologia, Inovações e Comunicações. Disponível em: <http://www2.cemaden.gov.br/redegeo-e-informacoes-sobre-umidade-de-solo-das-encostas-para-prevencao-de-deslizamentos-sao-apresentadas-pelo-cemaden/>. Acesso em: 28 de março de 2023.

CEMADEM (2022). **Acordo entre Brasil e Japão (GIDES)**. Ministério da Ciência, Tecnologia, Inovações e Comunicações. Disponível em: <https://www.gov.br/cemaden/pt-br/paginas/acordo-entre-brasil-e-japao-gides> .Acesso em: 12 de junho de 2023.

CHAVES, F. C. (2016) **Proposta de correlação chuva vs escorregamento aplicada à cidade do Rio de Janeiro**. Dissertação de Mestrado em Geotecnia, UERJ, Rio de Janeiro, RJ.

COUTINHO, R.; MORAIS, B.; MENDES, R.; ANDRADE, M. (2023). **Alert scenarios for the Metropolitan Region of Recife-PE based on monitoring of rainfall and soil humidity – a case study**. *Soils and Rocks*. 46. e2023008323. 10.28927/SR.2023.008323.

CPRM (2014). **Cartas de Susceptibilidade a movimentos gravitacionais e inundações**. Ministério de Minas e Energia. Disponível em: <http://www.cprm.gov.br/publique/Gestao-Territorial/Prevencao-de-Desastres/Produtos-por-Estado---Cartas-de-Suscetibilidade-a-Movimentos-Gravitacionais-de-Massa-e-Inundacoes-5384.html>. Acesso em: 29 de março de 2023.

CPRM (2013). **Nova Friburgo ganha mapas de suscetibilidade**. Ministério de Minas e Energia. Disponível em: <https://cprmblog.blogspot.com/2013/08/nova-friburgo-ganha-mapas-de.html>. Acesso em: 29 de março de 2023.

CRUDEN D. M., VARNES D. J. (1996). **Landslides, Investigation and Mitigation. Landslide types and processes** Bussines Office. Washington, DC Transportation Research Board. Washington DC, USA, 36-75 p.

DESC (2005). **Manual for the method of setting for mass-movement disasters warning criterion based on rainfall indices**. Department of Erosion and Sediment Control. Ministry of Land, Infrastructure, Transport and Tourism. Japan Meteorological Agency and National Institute for Land and Infrastructure Management. (Draft), 21p (2005): (in Japanese).

DIKSHIT, A.; SATYAM, N.; PRADHAN, B.; KUSHAL, S. (2020). **Estimating rainfall threshold and temporal probability for landslide occurrences in Darjeeling Himalayas**. *Geosciences Journal*, v. 24, n. 2, p. 225–233. DOI: 10.1007/s12303-020-0001-3.

D'ORSI, R.N. (2011) **Correlação entre pluviometria e escorregamentos no trecho da serra dos órgãos da rodovia federal BR-116RJ (Rio-Teresópolis)**. Tese de Doutorado, COPPE, UFRJ, Rio de Janeiro, RJ, 287 p.

D'ORSI, R.N. PAES, N.M., MAGALHÃES, M. A. COELHO, R. S. (2012) **Relatório Anual de Chuvas 2010. Relatório GEO-RIO/DEP/GPE – Nº 01/2012**, Diretoria de Estudos e Projetos – Gerência de Programas Especiais – Prefeitura do Rio de Janeiro.

D'ORSI, R, PAES, N.M., MAGALHÃES, M. A. COELHO, R. S. (2012) **Relatório de Correlação entre Chuvas e Escorregamentos para a Cidade do Rio de Janeiro no ano de 2010. Relatório GEO-RIO/DEP/GPE – Nº 10/2012**. Diretoria de Estudos e Projetos – Gerência de Programas Especiais – Prefeitura do Rio de Janeiro.

DRAELOS, R. (2019). **Measuring Performance: AUC (AUROC)**. Disponível em: <https://glassboxmedicine.com/2019/02/23/measuring-performance-auc-AUROC/>.

Acesso em: 06 de maio de 2023.

EHRlich, M.; LUIZ, B.; Mendes, C.; Lacerda, Willy. (2021). **Triggering factors and critical thresholds for landslides in Rio de Janeiro-RJ, Brazil**. Natural Hazards. 107. 10.1007/s11069-021-04616-w.

FENG, L.; MINGMING, G.; WENLONG, W.; YULAN, C.; QIANHUA, S.; WENZHAO G.; YIBAO L.; HONGLIANG K.; ZHOUXIN C.; YANAN Z. (2023) **Comparative Analysis of Machine Learning Methods and a Physical Model for Shallow Landslide Risk Modeling**. Sustainability (Switzerland), v. 15, n. 1, p. 1–18. DOI: 10.3390/su15010006.

FENG, X., LI, S., YUAN, C. ZENG, P., SUN, Y. (2018). **Prediction of Slope Stability Using Naive Bayes Classifier**. KSCE Journal of Civil Engineering 22(3): 941–50.

FIGUEIREDO, A. T. (2004) **Lecture Notes on Bayesian Estimation and Classification**. Instituto de Telecomunicações e Instituto Superior Técnico 1049-001, Lisboa, Portugal. Disponível em: https://www.lx.it.pt/~mtf/learning/Bayes_lecture_notes.pdf. Acesso em: 10 de março de 2022.

FLORES, E. A. F. (2008) **Análises probabilísticas da estabilidade de taludes considerando a variabilidade espacial do solo**. Dissertação de Mestrado em Engenharia Civil, Geotecnia, PUC-RIO, Rio de Janeiro, RJ.

FOURIE, A. B., BLIGHT, G. E., PINHEIRO, J. (1999) **Subsurface contamination by leachate at six unlined landfill sites in South Africa**. 7th Int. Waste Man. e and Landfill Symp. Cagliari, Italy, 1, 133-140.

FUNDAÇÃO INSTITUTO DAS ÁGUAS DO MUNICÍPIO DO RIO DE JANEIRO (2015) **Plano Municipal de Saneamento Básico da Cidade do Rio de Janeiro, Drenagem e Manejo de Águas Pluviais Urbanas**. Secretaria Municipal de Recursos Hídricos. Prefeitura da Cidade do Rio de Janeiro. Disponível em: https://www.rio.rj.gov.br/dlstatic/10112/5302963/4152314/PMSB_DRENAGEMEMAN_EJODEAGUASPLUVIAIS.pdf . Acesso em 18 de outubro de 2019.

GARCÍA, J. P.; FERREIRA, J. C.; PATINO, C. M. (2021). **Receiver Operating Characteristic Analysis: An Ally in the Pandemic**. JAMA Internal Medicine, v. 181, n. 3, p. 409. Disponível em: <https://www.scielo.br/j/jbpneu/a/9BWKy6dFzRhRmvgVjBhgynD/?lang=en&format=pdf> . Acesso em 18 de setembro de 2023.

GAVIN, K., XUE, J., (2008) **A simple method to analyze infiltration into unsaturated soil slopes**. Computers and Geotechnics, Volume 35, Issue 2, 223-230.

GEO-RIO (2010). **Relatórios Anuais de Escorregamento**. Prefeitura do Rio de Janeiro. Disponível em: <http://AlertaRio.rio.rj.gov.br/documentos/relatorios-anuais-de-escorregamento/> .Acesso em: 18 de março de 2022.

GEO-RIO (2011). **Relatórios Anuais de Escorregamento**. Prefeitura do Rio de Janeiro. Disponível em: <http://AlertaRio.rio.rj.gov.br/documentos/relatorios-anuais-de-escorregamento/> .Acesso em: 18 de março de 2022.

GEO-RIO (2015). **Mapa de Suscetibilidade**. Prefeitura do Rio de Janeiro. Disponível em: <https://www.data.rio/apps/suscetibilidade-a-deslizamentos/explore> . Acesso em: 18 de março de 2022.

GERSCOVICH, D. M. S. (2012), **Estabilidade de Taludes**. Primeira Edição. Oficina de Textos.

GIOVANNI, (2020). GES DISC. Disponível em: <https://disc.gsfc.nasa.gov/information/tools?title=Giovanni> . Acesso em: 16 de agosto de 2021.

GUIDICINI, G., IWASA, O.Y., (1976) “**Ensaio de Correlação entre Pluviometria e Deslizamentos em Meio Tropical Úmido**”. In: Simpósio Landslides and other Mass Moviment da IAEG, 1977, Praga, Publicação 1080 IPT.

GUIDICINI, G., NIEBLE, C.M. (1984). **Estabilidade de Taludes Naturais e de Escavação**. Edgard Blücher, São Paulo, 1 vol. 50-51

GUIDICINI G., CERRI. L. E. S. (1987) **Análise de correlação entre chuvas e escorregamentos, Serra do mar, Município de Cubatão**. Instituto de Pesquisa Tecnológica do Estado de São Paulo – IPT.

GUZZETTI, F.; GARIANO, S. L.; PERUCCACCI, S.; BRUNETTI, M. T.; MARCHESINI, I.; ROSSI, M.; MELILLO, M. (2020). **Geographical landslide early warning systems**. Earth-Science Reviews, v. 200. DOI: 10.1016/j.earscirev.2019.102973.

HABIBZADEH, F.; HABIBZADEH, P.; YADOLLAHIE, M. (2014). **On Determining the Most Appropriate Test Cut-off Value: the case of tests with continuous results**. [S. l.], v. 24, n. 3, p. 311–320.

HASSAN, V. V.; BARCELLOS, P. C. L.; SILVA, J. C. (2018). **Predictive Method for Activation of Sirens in Vulnerable Communities to Landslides in the Duque de Caxias City, Rio de Janeiro State, Brazil**. Anuário do Instituto de Geociências - UFRJ, v. 40, n. 1, p. 127–134. DOI: 10.11137/2017_1_127_134.

HUNGR, O.; LEROUEIL, S.; PICARELLI, L. (2014). **The Varnes classification of landslide types, an update**. Landslides, v. 11, n. 2, p. 167–194, 2014. DOI: 10.1007/s10346-013-0436-y.

HUTCHINSON, J.N. (1988). **General Report: Morphological and geotechnical parameter of landslides in relation to geology and hydrogeology**. Landslides, Proc. Fifth Int. Symp. on Landslides, (Ed. C. Bonnard), Lausanne, Switzerland, 1, 3-35 p.

IBM (2021). **ROC Analysis**. Disponível em: <https://www.ibm.com/docs/en/spss-statistics/beta?topic=features-roc-analysis> . Acesso em: 24 de setembro de 2023.

IBM (2024). **Analyzing data and working with models: SMOTE Node**. Disponível em: <https://dataplatform.cloud.ibm.com/docs/content/wsd/nodes/smote.html?context=cpdaas&audience=wdp> . Acesso em: 14 de fevereiro de 2024.

IMBALANCED-LEARN (2024). **Imbalanced-Learn Documentation: Common pitfalls and recommended practices**. Disponível em: https://imbalanced-learn.org/stable/common_pitfalls.html. Acesso em: 14 de fevereiro de 2024.

IRPI (2007). **Rainfall thresholds fo the initiation of landslides**. Istituto de Ricerca per la Protezione Idrogeológica. Disponível em: <http://rainfallthresholds.irpi.cnr.it/>. Acesso em: 21 de abril de 2023.

JARDIM, C.; SILVA, A. (2017). **Aplicação de técnicas de preenchimento de falhas de dados de pluviosidade mensal e anual para o noroeste do estado de Minas Gerais - Brasil**. Revista Geografias, v. 13, p. 83–106. DOI: 10.35699/2237-549x.2017.16058.

KONG, V. W. W.; KWAN, J. S. H.; PUN, W. K. (2020). **Hong Kong' s landslip warning system, 40 years of progress**. Springer Nature, n. February, 2020. DOI: 10.1007/s10346-020-01379-6.

LARSON, R., FARBER, B. (2010). **Estatística Aplicada**, 4ª edição, Ed. Pearson, São Paulo.

LEE, M. J.; PARK, I.; WON, J. S.; LEE, S. (2016). **Landslide hazard mapping considering rainfall probability in Inje, Korea**. Geomatics, Natural Hazards and Risk, v. 7, n. 1, p. 424–446. DOI: 10.1080/19475705.2014.931307.

LI, D. C., Shi, Q. S., Lin, Y. S., Lin, L. S (2022). **A Boundary-Information-Based Oversampling Approach to Improve Learning Performance for Imbalanced Datasets**. Entropy, v. 24, n. 3.

LUCCHESI, L. V. (2022) **Modelagem de suscetibilidade e de limiares de precipitação para deslizamentos de terra utilizando métodos de aprendizagem de máquina**. Tese de Doutorado em Recursos Hídricos e Saneamento Ambiental, UFRGS, Rio Grande do Sul, RS.

LUMB, P. (1975) **Slope failures in Hong Kong**. Department of civil engineering, University of Hong Kong. Engineering Geology 1975 vol 8 pp. 38-65.

MACHADO, I. F., DRIEMEIER, L. (2020) **Machine Learning: An Introduction**. PMR5251 - Avaliação do Comportamento Mecânico de Materiais Utilizando uma Abordagem de ML. Escola Politécnica da Universidade de São Paulo – USP. Notas de Aula. Disponível em: https://edisciplinas.usp.br/pluginfile.php/5728638/mod_resource/content/1/Aula01_Introd_ML.pdf. Acesso em: 16 de agosto de 2021.

MANDREKAR, J. N.(2010). **Receiver operating characteristic curve in diagnostic test assessment**. Journal of Thoracic Oncology, v. 5, n. 9, p. 1315–1316. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1556086415306043>. Acesso em: 20 de agosto de 2023.

MARTINS, T. F. (2014). **Pluviometria de escorregamentos na cidade do Rio de Janeiro: Comparação entre Regiões e Períodos**. Dissertação de Mestrado do Programa de Pós-graduação em Engenharia Civil – COPPE, Universidade Federal do Rio de Janeiro.

MATHWORKS (2023). **What Is Overfitting?**. Accelerating the pace of engineering and science. Disponível em: <https://www.mathworks.com/discovery/overfitting.html>. Acesso em: 29 de agosto de 2023.

MELILLO, M., BRUNETTI, M.T., PERUCCACCI, S., GARIANO, S.L., ROCCATI, A., GUZZETTI, F. (2018). **A tool for the automatic calculation of rainfall thresholds for landslide occurrence**. Environ. Model. Softw. 105, 230–243. <https://doi.org/10.1016/j.envsoft.2018.03.024>.

MELILLO, M., BRUNETTI, M.T., PERUCCACCI, S., GARIANO, S.L., GUZZETTI, F. (2014). **An Algorithm for the objective reconstruction of rainfall events responsible for landslides**. Landslide Dyn. ISDR-ICL Landslide Interact. Teach. Tools, Vol. 1 Fundam. Mapp. Monit. 12, 311–320. https://doi.org/10.1007/978-3-319-57774-6_33.

MDR (2019). **Projeto GIDES**. Ministério do Desenvolvimento Regional. Disponível em: <https://antigo.mdr.gov.br/component/content/article/293-secretaria-nacional-de-protecao-e-defesa-civil/11876-projeto-gides>. Acesso em: 12 de agosto de 2023.

MICHELETTI, N., FORESTI, L., ROBERT, S., LEUENBERGER, M., PEDRAZZINI, A., JABOYEDOFF, M., KANEVSKI, M. (2014). **Machine Learning Feature Selection Methods for Landslide Susceptibility Mapping**. *Mathematical Geosciences* 46(1): 33–57.

MIRUS, B. B.; BECKER, R. E.; BAUM, R. L.; SMITH, J. B. (2018). **Integrating real-time subsurface hydrologic monitoring with empirical rainfall thresholds to improve landslide early warning**. *Landslides*, v. 15, n. 10, p. 1909–1919, 2018. DOI: 10.1007/s10346-018-0995-z.

MIT (2021). **Collaborative Data Science for Healthcare**. Open Learning Library. Massachusetts Institute of Technology. Disponível em: <https://openlearninglibrary.mit.edu/courses/course-v1:MITx+HST.953x+3T2020/course/>. Acesso em: 10 de agosto de 2022.

MITCHELL, T (1998). **Machine Learning**. McGraw Hill series in computer science.

MOHAN, A.; SINGH, A. K.; KUMAR, B.; DWIVEDI, R. (2021). **Review on remote sensing methods for landslide detection using machine and deep learning**. *Transactions on Emerging Telecommunications Technologies*, v. 32, n. 7, p. 1–23, 2021. DOI: 10.1002/ett.3998.

MONTOYA, E. (2013). **Modelo de alerta de escorregamentos deflagrados por chuvas usando redes neurais artificiais**. Dissertação de Mestrado em Engenharia Civil, UnB, Brasília, DF.

MUCCIOLI, C; CAMPOS, M; GOLDCHMIT, M; DANTAS, P. E. C.; BECHARA, S. J.; COSTA, V. P. (2007). **Pesquisa científica, inovação e desenvolvimento**. *Arquivos Brasileiros de Oftalmologia*, [S. l.], v. 70, n. 3, p. 383–383, 2007. DOI: 10.1590/s0004-27492007000300001.

NG, C.W.W., SHI, Q. (1998) **Influence on rainfall intensity and duration on slope stability in unsaturated soils**. *Quarterly journal of Engineering Geology* 31: 105-113.

NIPPON (2019). **New Five-Level Warning System Introduced for Heavy Rain Disasters**. Disponível em: <https://www.nippon.com/en/japan-data/h00466/new-five-level-warning-system-introduced-for-heavy-rain-disasters.html> .Acesso em: 11 de agosto de 2023.

OGUNSANYA, M.; ISICHEI, J.; DESAI, S. (2023). **Grid search hyperparameter tuning in additive manufacturing processes**. . Manufacturing Letters, v. 35, p. 1031–1042. DOI: 10.1016/j.mfglet.2023.08.056.

DE OLIVEIRA E SILVA, D. C.; LIVRAMENTO, K.; EHRLICH, M.; NOSEDA, F. (2024), **Critical Threshold Curves for Landslides in the Rio De Janeiro City by Long Term Rainfall Monitoring**. Available at SSRN: <https://ssrn.com/abstract=4837620> or <http://dx.doi.org/10.2139/ssrn.4837620>

OSANAI, N.; SHIMIZU, T.; KURAMOTO, K.; KOJIMA, S.; NORO, T. (2010). **Japanese early-warning for debris flows and slope failures using rainfall indices with Radial Basis Function Network**. Springer-Verlag, n. November 2009, p. 325–338, 2010. DOI: 10.1007/s10346-010-0229-5.

PALIWAL, M.; GOSWAMI, H.; RAY, A.; BHARATI, A. K.; RAI, R.; KHANDELWAL, M. (2022). **Stability Prediction of Residual Soil and Rock Slope Using Artificial Neural Network**. Hindawi, v. 2022. DOI: 10.1155/2022/4121193.

PARK, J.; LEE, S.; LEE, D.; KIM, Y.; LEE, J. (2019). **A regional-scale landslide early warning methodology applying statistical and physically based approaches in sequence**. Engineering Geology, v. 260, n. June, p. 105193, 2019. DOI: 10.1016/j.enggeo.2019.105193.

PERUCCACCI, S.; BRUNETTI, M. T.; LUCIANI, S.; VENNARI, C.; GUZZETTI, F. (2012). **Lithological and seasonal control on rainfall thresholds for the possible initiation of landslides in central Italy**. Geomorphology, doi: 10.1016/j.geomorph.2011.10.005.

PERUCCACCI, S.; BRUNETTI, M. T.; GARIANO, S. L.; MELILLO, M.; ROSSI, M.; GUZZETTI, F. (2017). **Rainfall thresholds for possible landslide occurrence in Italy**. Geomorphology, DOI: 10.1016/J.GEOMORPH.2017.03.031.

PHAM, B. T.; PRAKASH, I.; JAAFARI, A.; BUI, D. T. (2018). **Spatial Prediction of Rainfall-Induced Landslides Using Aggregating One-Dependence Estimators Classifier**. Journal of the Indian Society of Remote Sensing, v. 46, n. 9, p. 1457–1470, 2018. DOI: 10.1007/s12524-018-0791-1.

POLO, M.; MIOT, H. (2020) **Use of roc curves in clinical and experimental studies**. Jornal Vascular Brasileiro, v. 19, p. 1–4. DOI: 10.1590/1677-5449.200186.

PREMCHITT, J. (1991) **Salient aspects of landslides in Hong Kong**. Proceedings of the ninth Asian Regional Conference on Soil Mechanics and Foundation Engineering, Bangkok, vol. 2, 497-502.

PREMCHITT, J., BRAND, E. W., CHEN, P. Y. M. (1994) **“Rain induced landslides in Hong Kong, 1972-1992”**, Asia Engineer.

PUN, W.K., WONG, A.K.W. and PANG, P.L.R. (2003) **A review of the relationship between rainfall and landslides in Hong Kong**. Proceedings of the Asian Technical Committee (ATC 3) workshop on rain-induced landslides, Hong Kong, vol. 3, pp 211-217.

RAHARDJO, H.; FREDLUND, D. G. (1993). **“Stress paths for shear strength testing of unsaturated soils**, “Proc. Of the 11th S.E.A.G.C. (Singapore), May 4-8.

RAMALHO, G. (2017). **Estação do alto da boa vista bate recorde de chuva dos últimos 20 anos**. o Globo Rio. Disponível em <https://oglobo.globo.com/rio/estacao-do-alto-da-boa-vista-bate-recorde-de-chuva-dos-ultimos-20-anos-21501493>. Acesso em: 24 de abril de 2023.

RAMEZANKHANI, A., POURNIK, O., SHAHRABI, J., AZIZI, F., HADAEGH, F., KHALILI, D. (2016). **The impact of oversampling with SMOTE on the performance of 3 classifiers in prediction of type 2 diabetes**. Medical Decision Making, v. 36, n. 1, p. 137–144.

REICHENBACH, P.; ROSSI, M.; MALAMUD, B. D.; MIHIR, M.; GUZZETTI, F. (2018). **A review of statistically-based landslide susceptibility models**. Earth-Science Reviews, v. 180, n. March, p. 60–91. DOI: 10.1016/j.earscirev.2018.03.001.

RHYS, L. H.(2020). **Machine Learning with R, the Tidyverse**. Manning Publications; 1ª edição.

ROGOZHNIKOV, A. (2015). **Roc curve demonstration**. Disponível em: <https://arogozhnikov.github.io/2015/10/05/roc-curve.html>. Acesso em: 06 de março de 2023.

ROSSI, M.; PERUCCACCI, S.; BRUNETTI, M. T.; MARCHESINI, I.; LUCIANI, S.; ARDIZZONE, F.; BALDUCCI, V.; BIANCHI, C.; CARDINALI, M.; FIORUCCI, F.; MONDINI, A C.; REICHENBACH, P.; SALVATI, P.; SANTANGELO, M.; BARTOLINI, D.; GARIANO, S L.; PALLADINO, M.; VESSIA, G.; VIERO, A.; ANTRONICO, L.; BORSELLI, L.; DEGANUTTI, A M.; IOVINE, G.; LUINO, F.; PARISE, M.; POLEMIO, M.; GUZZETTI, F. (2012) . **SANF : National warning system for rainfall-induced landslides in Italy. [S. I.]**, p. 1895–1899.

SAMEEN, M. I.; SARKAR, R.; PRADHAN, B.; DRUKPA, D.; ALAMRI, A. M.; PARK, H. J. (2020). **Landslide spatial modelling using unsupervised factor optimisation and regularised greedy forests**. Computers and Geosciences, v. 134, p. 104336, 2020. DOI: 10.1016/j.cageo.2019.104336.

SAMUEL, A. L. (1959). **Some studies in machine learning using the game of checkers**. IBM Journal of Research and Development, 3(3), 210-229.

SANTOS, A. R. (2004) **A grande barreira da Serra do Mar: Trilha dos imigrantes**. O Nome da Rosa, São Paulo, 39-45

SCIKIT-LEARN (2007) Machine Learning in Python - Library. Disponível em: <https://scikit-learn.org/stable/index.html>. Acesso em: 05 de agosto de 2022.

SEEFELDER, C. L. N. (2017). **Estudo da influência dos parâmetros hidrogeológicos na análise de susceptibilidade a escorregamentos rasos por meio de modelo de estabilidade de encostas**. Tese de Doutorado em Tecnologia Ambiental e Recursos Hídricos, UnB, Brasília, DF.

SEGONI, S.; ROSI, A.; FANTI, R.; GALLUCCI, A.; MONNI, A.; CASAGLI, N. (2018). **A Regional-Scale Landslide Warning System Based on 20 Years of Operational Experience**. MDPI-Water, v. 10, p. 1–17. DOI: 10.3390/w10101297.

SOUZA, F. T., HARRY, A. B., Krueger, J., SOUZA, G. R. (2017). **Técnicas de Mineração de Dados no Estudo de Desastres Naturais e Planejamento Urbano.**

ResearchGate. Disponível em:

www.researchgate.net/publication/268418018_tecnicas_de_mineracao_de_dados_no_estudo_de_desastres_naturais_e_planejamento_urbano_xx-00_-_tecnicas_de_mineracao_de_dados_no_estudo_de_desastres_naturais_e_planejamento_urbano. Acesso em: 16 de agosto de 2021.

VOVK, V. (2015). **The fundamental nature of the log loss function.** Springer International Publishing Switzerland, v. 9300, p. 307–318. DOI: 10.1007/978-3-319-23534-9.

TATIZANA, C., OGURA, A. T., CERRI, L. E. S. (1987), **Análise de correlação entre chuvas e escorregamentos, Serra do mar, Município de Cubatão.** Instituto de Pesquisa Tecnológica do Estado de São Paulo – IPT.

TEJA, T. S.; DIKSHIT, A.; SATYAM, N. (2019). **Determination of rainfall thresholds for landslide prediction using an algorithm-based approach: Case study in the Darjeeling Himalayas, India.** Geosciences (Switzerland), v. 09, n. 7. DOI: 10.3390/geosciences9070302.

TORRES, F. R., TRINIDAD, J. F. M., OCHOA, J. A. C. (2022). **An Oversampling Method for Class Imbalance Problems on Large Datasets.** Applied Sciences, v. 12, n. 7.

TREESA, M.; SATYAM, N.; ROSI, A.; PRADHAN, B.; SEGONI, S. (2021). **Usage of antecedent soil moisture for improving the performance of rainfall thresholds for landslide early warning.** Catena, v. 200, n. October, p. 105147, 2021. DOI: 10.1016/j.catena.2021.105147.

TSANGARATOS, P.; ILIA, L. (2016). **Comparison of a logistic regression and Naïve Bayes classifier in landslide susceptibility assessments: The influence of models complexity and training dataset size.** Catena, v. 145, p. 164–179, 2016. DOI: 10.1016/j.catena.2016.06.004.

TUSTUMI, F. (2022). **Choosing the most appropriate cut-point for continuous variables**. Revista do Colégio Brasileiro de Cirurgiões, [S. l.], v. 49, p. 1–4. DOI: 10.1590/0100-6991e-20223346-en.

UNICAMP (2022). **Petrópolis: não foi um desastre natural!**. Jornal da UNICAMP. Disponível em: <https://www.unicamp.br/unicamp/ju/noticias/2022/02/22/petropolis-nao-foi-um-desastre-natural>. Acesso em: 30 de março de 2023.

TUCCI, C. E. M. (2009), **Hidrologia: Ciência e Aplicação**, Editora UFRGS, Porto Alegre – RS.

VALLET, A.; VARRON, D.; BERTRAND, C.; FABBRI, O.; MUDRY, J. (2016). **A multi-dimensional statistical rainfall threshold for deep landslides based on groundwater recharge and support vector machines**. Natural Hazards, v. 84, n. 2, p. 821–849, 2016. DOI: 10.1007/s11069-016-2453-3.

VARNES D. J. (1984). **Landslide Hazard zonation: a Review of Principles and Practice**. - Unesco, Paris, France, 63 p.

VARNES, D. J. (1978). **Slope movements types and processes**. In: Schuster R.L., y Krizek R.J. (ed.). Landslides analysis and control. Washington D. C, National Academy Press, Transportation Research Board Special Report, 176, 9-33 p.

VASCONCELLOS, D. B. (2015). **Percepção de Risco associados a deslizamentos de terra da Comunidade do Morro da Formiga**, Rio de Janeiro. Projeto de Graduação em Engenharia Civil, UFRJ, Rio de Janeiro, RJ.

WICKI, A.; LEHMANN, P.; HAUCK, C.; SENEVIRATNE, S. I.; WALDNER, P.; STÄHLI, M. (2020). **Assessing the potential of soil moisture measurements for regional landslide early warning**. Landslides, v. 17, n. 8, p. 1881–1896, 2020. DOI: 10.1007/s10346-020-01400-y.

WILBER, J. (2022) **ROC e AUC - A Visual Explanation of Receiver Operating Characteristic Curves and Area Under the Curve**. Disponível em <https://mlu-explain.github.io/roc-auc/>. Acesso em: 20 de outubro de 2023.

- WILBER, J. (2023) **Neural Networks**. Disponível em <https://mlu-explain.github.io/neural-networks/>. Acesso em: 21 de outubro de 2023.
- WOOD, T. (2020) **Random Forests**. Disponível em <https://deeptai.org/machine-learning-glossary-and-terms/random-forest>. Acesso em: 05 de abril de 2023.
- YANG, L.; SHAMI, A. (2020) **On Hyperparameter Optimization Of Machine Learning Algorithms: Theory And Practice**. Neurocomputing, v. 415, p. 295–316, 2020. DOI: <https://doi.org/10.1016/j.neucom.2020.07.061>.
- YEON, J; WILBER, J. (2020) **Random Forests Algorithm - How the majority vote and well-placed randomness can enhance the decision tree model**. Disponível em <https://mlu-explain.github.io/random-forest/>. Acesso em: 20 de outubro de 2023.
- ZHANG, J.; TANG, H.; TANNANT, D. D.; LIN, C.; XIA, D.; WANG, Y.; WANG, Q. (2021). **A novel model for landslide displacement prediction based on edr selection and multi-swarm intelligence optimization algorithm**. Sensors, v. 21, n. 24. DOI: [10.3390/s21248352](https://doi.org/10.3390/s21248352).
- ZHAO, B.; DAI, Q.; HAN, D.; DAI, H.; MAO, J.; ZHUO, L. (2019). **Probabilistic thresholds for landslides warning by integrating soil moisture conditions with rainfall thresholds**. Journal of Hydrology, v. 574, n. April, p. 276–287, 2019. DOI: [10.1016/j.jhydrol.2019.04.062](https://doi.org/10.1016/j.jhydrol.2019.04.062).

APÊNDICE A – DADOS DE ENTRADA

(a) Modulação da Precipitação – MP01

Tabela 67 – Dados de Entrada Classes (0) e (1) – MP01

| Referências | | Atributos/Fatores | | | | | | | | Rótulos |
|-------------|------------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|---------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Classe (Binária) |
| 1 | 21/01/2009 | 94 | 12 | 13 | 4 | 6 | 2 | 6 | 2 | 0 |
| 2 | 22/01/2009 | 23 | 9 | 94 | 12 | 13 | 4 | 6 | 2 | 0 |
| 3 | 23/01/2009 | 9 | 6 | 23 | 9 | 94 | 12 | 13 | 4 | 0 |
| 4 | 24/01/2009 | 6 | 5 | 9 | 6 | 23 | 9 | 94 | 12 | 0 |
| 5 | 12/02/2009 | 62 | 6 | 3 | 1 | 0 | 0 | 0 | 0 | 0 |
| 6 | 13/02/2009 | 4 | 4 | 62 | 6 | 3 | 1 | 0 | 0 | 0 |
| 7 | 14/02/2009 | 10 | 4 | 4 | 4 | 62 | 6 | 3 | 1 | 0 |
| 8 | 15/02/2009 | 0 | 0 | 10 | 4 | 4 | 4 | 62 | 6 | 0 |
| 9 | 23/04/2009 | 19 | 4 | 0 | 0 | 59 | 9 | 0 | 0 | 0 |
| 10 | 24/04/2009 | 0 | 0 | 19 | 4 | 0 | 0 | 59 | 9 | 0 |
| 11 | 21/09/2009 | 55 | 9 | 5 | 4 | 0 | 0 | 0 | 0 | 0 |
| 12 | 22/09/2009 | 2 | 2 | 55 | 9 | 5 | 4 | 0 | 0 | 0 |
| 13 | 23/09/2009 | 0 | 0 | 2 | 2 | 55 | 9 | 5 | 4 | 0 |
| 14 | 24/09/2009 | 6 | 5 | 0 | 0 | 2 | 2 | 55 | 9 | 0 |
| 15 | 08/10/2009 | 40 | 16 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 16 | 09/10/2009 | 70 | 16 | 40 | 16 | 0 | 0 | 0 | 0 | 0 |
| 17 | 10/10/2009 | 15 | 8 | 70 | 16 | 40 | 16 | 0 | 0 | 0 |
| 18 | 11/10/2009 | 0 | 0 | 15 | 8 | 70 | 16 | 40 | 16 | 0 |
| 19 | 12/10/2009 | 0 | 0 | 0 | 0 | 15 | 8 | 70 | 16 | 0 |

| Referências | | Atributos/Fatores | | | | | | | | Rótulos |
|-------------|------------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|---------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Classe (Binária) |
| 20 | 04/12/2009 | 66 | 15 | 2 | 1 | 3 | 1 | 0 | 0 | 1 |
| 21 | 05/12/2009 | 14 | 9 | 66 | 15 | 2 | 1 | 3 | 1 | 0 |
| 22 | 06/12/2009 | 0 | 0 | 14 | 9 | 66 | 15 | 2 | 1 | 0 |
| 23 | 07/12/2009 | 5 | 2 | 0 | 0 | 14 | 9 | 66 | 15 | 0 |
| 24 | 09/12/2009 | 57 | 9 | 16 | 13 | 5 | 2 | 0 | 0 | 0 |
| 25 | 10/12/2009 | 44 | 10 | 57 | 9 | 16 | 13 | 5 | 2 | 1 |
| 26 | 11/12/2009 | 1 | 1 | 44 | 10 | 57 | 9 | 16 | 13 | 1 |
| 27 | 12/12/2009 | 0 | 0 | 1 | 1 | 44 | 10 | 57 | 9 | 0 |
| 28 | 30/12/2009 | 53 | 10 | 12 | 3 | 14 | 4 | 24 | 2 | 1 |
| 29 | 31/12/2009 | 46 | 13 | 53 | 10 | 12 | 3 | 14 | 4 | 0 |
| 30 | 01/01/2010 | 0 | 0 | 46 | 13 | 53 | 10 | 12 | 3 | 0 |
| 31 | 02/01/2010 | 0 | 0 | 0 | 0 | 46 | 13 | 53 | 10 | 0 |
| 32 | 15/01/2010 | 76 | 10 | 20 | 3 | 0 | 0 | 0 | 0 | 1 |
| 33 | 16/01/2010 | 1 | 1 | 76 | 10 | 20 | 3 | 0 | 0 | 1 |
| 34 | 17/01/2010 | 0 | 0 | 1 | 1 | 76 | 10 | 20 | 3 | 0 |
| 35 | 18/01/2010 | 0 | 0 | 0 | 0 | 1 | 1 | 76 | 10 | 0 |
| 36 | 22/01/2010 | 58 | 5 | 2 | 1 | 5 | 1 | 7 | 1 | 0 |
| 37 | 23/01/2010 | 0 | 0 | 58 | 5 | 2 | 1 | 5 | 1 | 0 |
| 38 | 24/01/2010 | 3 | 1 | 0 | 0 | 58 | 5 | 2 | 1 | 0 |
| 39 | 25/01/2010 | 26 | 6 | 3 | 1 | 0 | 0 | 58 | 5 | 0 |
| 40 | 01/03/2010 | 57 | 19 | 2 | 2 | 1 | 1 | 6 | 3 | 0 |
| 41 | 02/03/2010 | 7 | 6 | 57 | 19 | 2 | 2 | 1 | 1 | 0 |
| 42 | 03/03/2010 | 3 | 2 | 7 | 6 | 57 | 19 | 2 | 2 | 0 |
| 43 | 04/03/2010 | 2 | 2 | 3 | 2 | 7 | 6 | 57 | 19 | 0 |

| Referências | | Atributos/Fatores | | | | | | | | Rótulos |
|-------------|------------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|---------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Classe (Binária) |
| 44 | 06/03/2010 | 90 | 5 | 4 | 2 | 2 | 2 | 3 | 2 | 1 |
| 45 | 07/03/2010 | 0 | 0 | 90 | 5 | 4 | 2 | 2 | 2 | 1 |
| 46 | 08/03/2010 | 0 | 0 | 0 | 0 | 90 | 5 | 4 | 2 | 0 |
| 47 | 09/03/2010 | 0 | 0 | 0 | 0 | 0 | 0 | 90 | 5 | 0 |
| 48 | 16/03/2010 | 15 | 6 | 5 | 2 | 41 | 5 | 3 | 1 | 0 |
| 49 | 17/03/2010 | 39 | 9 | 15 | 6 | 5 | 2 | 41 | 5 | 1 |
| 50 | 18/03/2010 | 0 | 0 | 39 | 9 | 15 | 6 | 5 | 2 | 0 |
| 51 | 31/03/2010 | 32 | 7 | 23 | 6 | 16 | 2 | 0 | 0 | 0 |
| 52 | 01/04/2010 | 4 | 3 | 32 | 7 | 23 | 6 | 16 | 2 | 0 |
| 53 | 05/04/2010 | 102 | 9 | 10 | 2 | 0 | 0 | 0 | 0 | 1 |
| 54 | 06/04/2010 | 182 | 21 | 102 | 9 | 10 | 2 | 0 | 0 | 1 |
| 55 | 07/04/2010 | 24 | 7 | 182 | 21 | 102 | 9 | 10 | 2 | 0 |
| 56 | 08/04/2010 | 17 | 5 | 24 | 7 | 182 | 21 | 102 | 9 | 0 |
| 57 | 09/04/2010 | 15 | 4 | 17 | 5 | 24 | 7 | 182 | 21 | 1 |
| 58 | 29/04/2010 | 18 | 9 | 48 | 7 | 4 | 2 | 0 | 0 | 0 |
| 59 | 30/04/2010 | 2 | 1 | 18 | 9 | 48 | 7 | 4 | 2 | 0 |
| 60 | 01/05/2010 | 0 | 0 | 2 | 1 | 18 | 9 | 48 | 7 | 0 |
| 61 | 09/05/2010 | 43 | 14 | 2 | 1 | 0 | 0 | 0 | 0 | 0 |
| 62 | 10/05/2010 | 8 | 3 | 43 | 14 | 2 | 1 | 0 | 0 | 0 |
| 63 | 11/05/2010 | 0 | 0 | 8 | 3 | 43 | 14 | 2 | 1 | 0 |
| 64 | 12/05/2010 | 7 | 1 | 0 | 0 | 8 | 3 | 43 | 14 | 0 |
| 65 | 16/07/2010 | 30 | 9 | 14 | 9 | 29 | 11 | 6 | 1 | 0 |
| 66 | 17/07/2010 | 58 | 14 | 30 | 9 | 14 | 9 | 29 | 11 | 0 |
| 67 | 18/07/2010 | 7 | 3 | 58 | 14 | 30 | 9 | 14 | 9 | 0 |

| Referências | | Atributos/Fatores | | | | | | | | Rótulos |
|-------------|------------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|---------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Classe (Binária) |
| 68 | 19/07/2010 | 0 | 0 | 7 | 3 | 58 | 14 | 30 | 9 | 0 |
| 69 | 20/07/2010 | 0 | 0 | 0 | 0 | 7 | 3 | 58 | 14 | 0 |
| 70 | 26/10/2010 | 33 | 8 | 0 | 0 | 0 | 1 | 7 | 2 | 0 |
| 71 | 27/10/2010 | 49 | 5 | 33 | 8 | 0 | 0 | 0 | 1 | 0 |
| 72 | 28/10/2010 | 0 | 0 | 49 | 5 | 33 | 8 | 0 | 0 | 0 |
| 73 | 29/10/2010 | 0 | 0 | 0 | 0 | 49 | 5 | 33 | 8 | 0 |
| 74 | 30/10/2010 | 7 | 1 | 0 | 0 | 0 | 0 | 49 | 5 | 0 |
| 75 | 05/12/2010 | 70 | 4 | 0 | 0 | 2 | 1 | 20 | 2 | 0 |
| 76 | 06/12/2010 | 6 | 2 | 70 | 4 | 0 | 0 | 2 | 1 | 0 |
| 77 | 07/12/2010 | 0 | 1 | 6 | 2 | 70 | 4 | 0 | 0 | 0 |
| 78 | 08/12/2010 | 0 | 0 | 0 | 1 | 6 | 2 | 70 | 4 | 0 |
| 79 | 12/01/2011 | 5 | 1 | 52 | 13 | 3 | 1 | 0 | 0 | 0 |
| 80 | 13/01/2011 | 3 | 1 | 5 | 1 | 52 | 13 | 3 | 1 | 0 |
| 81 | 14/01/2011 | 2 | 1 | 3 | 1 | 5 | 1 | 52 | 13 | 0 |
| 82 | 25/04/2011 | 103 | 4 | 48 | 4 | 0 | 0 | 0 | 0 | 1 |
| 83 | 26/04/2011 | 60 | 8 | 103 | 4 | 48 | 4 | 0 | 0 | 1 |
| 84 | 27/04/2011 | 7 | 3 | 60 | 8 | 103 | 4 | 48 | 4 | 0 |
| 85 | 28/04/2011 | 0 | 1 | 7 | 3 | 60 | 8 | 103 | 4 | 0 |
| 86 | 29/04/2011 | 0 | 0 | 0 | 1 | 7 | 3 | 60 | 8 | 0 |
| 87 | 13/05/2011 | 31 | 7 | 1 | 0 | 0 | 0 | 19 | 6 | 0 |
| 88 | 16/05/2011 | 13 | 5 | 0 | 1 | 5 | 3 | 31 | 7 | 0 |
| 89 | 28/05/2011 | 15 | 5 | 34 | 8 | 0 | 0 | 0 | 0 | 0 |
| 90 | 29/05/2011 | 0 | 1 | 15 | 5 | 34 | 8 | 0 | 0 | 0 |
| 91 | 30/05/2011 | 0 | 0 | 0 | 1 | 15 | 5 | 34 | 8 | 0 |

| Referências | | Atributos/Fatores | | | | | | | | Rótulos |
|-------------|------------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|---------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Classe (Binária) |
| 92 | 14/09/2011 | 54 | 14 | 0 | 0 | 6 | 3 | 1 | 1 | 0 |
| 93 | 15/09/2011 | 4 | 3 | 54 | 14 | 0 | 0 | 6 | 3 | 0 |
| 94 | 16/09/2011 | 0 | 0 | 4 | 3 | 54 | 14 | 0 | 0 | 0 |
| 95 | 17/09/2011 | 0 | 0 | 0 | 0 | 4 | 3 | 54 | 14 | 0 |
| 96 | 17/10/2011 | 34 | 14 | 5 | 3 | 7 | 4 | 3 | 2 | 0 |
| 97 | 18/10/2011 | 9 | 4 | 34 | 14 | 5 | 3 | 7 | 4 | 0 |
| 98 | 19/10/2011 | 3 | 2 | 9 | 4 | 34 | 14 | 5 | 3 | 0 |
| 99 | 20/10/2011 | 0 | 0 | 3 | 2 | 9 | 4 | 34 | 14 | 0 |
| 100 | 27/12/2011 | 8 | 3 | 41 | 14 | 5 | 2 | 0 | 0 | 0 |
| 101 | 28/12/2011 | 15 | 5 | 8 | 3 | 41 | 14 | 5 | 2 | 0 |
| 102 | 29/12/2011 | 4 | 2 | 15 | 5 | 8 | 3 | 41 | 14 | 0 |
| 103 | 02/01/2012 | 52 | 17 | 10 | 8 | 5 | 3 | 0 | 0 | 0 |
| 104 | 03/01/2012 | 0 | 0 | 52 | 17 | 10 | 8 | 5 | 3 | 0 |
| 105 | 04/01/2012 | 0 | 0 | 0 | 0 | 52 | 17 | 10 | 8 | 0 |
| 106 | 01/05/2012 | 30 | 10 | 44 | 12 | 4 | 1 | 0 | 0 | 0 |
| 107 | 02/05/2012 | 0 | 1 | 30 | 10 | 44 | 12 | 4 | 1 | 0 |
| 108 | 03/05/2012 | 4 | 2 | 0 | 1 | 30 | 10 | 44 | 12 | 0 |
| 109 | 07/06/2012 | 46 | 8 | 7 | 5 | 0 | 0 | 0 | 0 | 0 |
| 110 | 08/06/2012 | 15 | 7 | 46 | 8 | 7 | 5 | 0 | 0 | 0 |
| 111 | 09/06/2012 | 36 | 13 | 15 | 7 | 46 | 8 | 7 | 5 | 0 |
| 112 | 10/06/2012 | 1 | 1 | 36 | 13 | 15 | 7 | 46 | 8 | 0 |
| 113 | 11/06/2012 | 4 | 2 | 1 | 1 | 36 | 13 | 15 | 7 | 0 |
| 114 | 12/06/2012 | 0 | 0 | 4 | 2 | 1 | 1 | 36 | 13 | 0 |
| 115 | 26/09/2012 | 75 | 15 | 19 | 4 | 0 | 0 | 0 | 0 | 0 |

| Referências | | Atributos/Fatores | | | | | | | | Rótulos |
|-------------|------------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|---------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Classe (Binária) |
| 116 | 27/09/2012 | 0 | 0 | 75 | 15 | 19 | 4 | 0 | 0 | 0 |
| 117 | 28/09/2012 | 0 | 0 | 0 | 0 | 75 | 15 | 19 | 4 | 0 |
| 118 | 29/09/2012 | 0 | 0 | 0 | 0 | 0 | 0 | 75 | 15 | 0 |
| 119 | 16/11/2012 | 5 | 2 | 9 | 5 | 6 | 3 | 32 | 12 | 0 |
| 120 | 04/01/2013 | 13 | 5 | 52 | 15 | 3 | 1 | 0 | 0 | 0 |
| 121 | 05/01/2013 | 0 | 0 | 13 | 5 | 52 | 15 | 3 | 1 | 0 |
| 122 | 06/01/2013 | 0 | 0 | 0 | 0 | 13 | 5 | 52 | 15 | 0 |
| 123 | 15/01/2013 | 47 | 3 | 10 | 4 | 0 | 0 | 1 | 1 | 1 |
| 124 | 16/01/2013 | 3 | 2 | 47 | 3 | 10 | 4 | 0 | 0 | 0 |
| 125 | 17/01/2013 | 31 | 4 | 3 | 2 | 47 | 3 | 10 | 4 | 1 |
| 126 | 18/01/2013 | 5 | 2 | 31 | 4 | 3 | 2 | 47 | 3 | 0 |
| 127 | 22/01/2013 | 46 | 6 | 32 | 7 | 14 | 3 | 5 | 1 | 1 |
| 128 | 23/01/2013 | 0 | 0 | 46 | 6 | 32 | 7 | 14 | 3 | 1 |
| 129 | 24/01/2013 | 0 | 0 | 0 | 0 | 46 | 6 | 32 | 7 | 0 |
| 130 | 27/01/2013 | 6 | 3 | 56 | 7 | 0 | 0 | 0 | 0 | 0 |
| 131 | 28/01/2013 | 4 | 3 | 6 | 3 | 56 | 7 | 0 | 0 | 0 |
| 132 | 29/01/2013 | 6 | 6 | 4 | 3 | 6 | 3 | 56 | 7 | 0 |
| 133 | 17/03/2013 | 58 | 7 | 2 | 2 | 5 | 1 | 14 | 5 | 0 |
| 134 | 18/03/2013 | 36 | 9 | 58 | 7 | 2 | 2 | 5 | 1 | 1 |
| 135 | 19/03/2013 | 4 | 3 | 36 | 9 | 58 | 7 | 2 | 2 | 0 |
| 136 | 20/03/2013 | 0 | 1 | 4 | 3 | 36 | 9 | 58 | 7 | 0 |
| 137 | 17/05/2013 | 98 | 15 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 138 | 18/05/2013 | 6 | 5 | 98 | 15 | 0 | 0 | 0 | 0 | 0 |
| 139 | 19/05/2013 | 0 | 1 | 6 | 5 | 98 | 15 | 0 | 0 | 0 |

| Referências | | Atributos/Fatores | | | | | | | | Rótulos |
|-------------|------------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|---------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Classe (Binária) |
| 140 | 20/05/2013 | 0 | 0 | 0 | 1 | 6 | 5 | 98 | 15 | 0 |
| 141 | 02/07/2013 | 38 | 9 | 16 | 3 | 0 | 0 | 0 | 0 | 0 |
| 142 | 03/07/2013 | 0 | 0 | 38 | 9 | 16 | 3 | 0 | 0 | 0 |
| 143 | 04/07/2013 | 0 | 0 | 0 | 0 | 38 | 9 | 16 | 3 | 0 |
| 144 | 05/07/2013 | 0 | 0 | 0 | 0 | 0 | 0 | 38 | 9 | 0 |
| 145 | 04/09/2013 | 45 | 15 | 8 | 3 | 0 | 0 | 0 | 0 | 0 |
| 146 | 05/09/2013 | 7 | 3 | 45 | 15 | 8 | 3 | 0 | 0 | 0 |
| 147 | 06/09/2013 | 0 | 0 | 7 | 3 | 45 | 15 | 8 | 3 | 0 |
| 148 | 07/09/2013 | 0 | 0 | 0 | 0 | 7 | 3 | 45 | 15 | 0 |
| 149 | 16/10/2013 | 38 | 14 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 150 | 17/10/2013 | 5 | 2 | 38 | 14 | 0 | 0 | 0 | 0 | 0 |
| 151 | 18/10/2013 | 12 | 3 | 5 | 2 | 38 | 14 | 0 | 0 | 0 |
| 152 | 19/10/2013 | 0 | 0 | 12 | 3 | 5 | 2 | 38 | 14 | 0 |
| 153 | 07/11/2013 | 42 | 17 | 20 | 13 | 10 | 3 | 0 | 0 | 0 |
| 154 | 08/11/2013 | 1 | 1 | 42 | 17 | 20 | 13 | 10 | 3 | 0 |
| 155 | 09/11/2013 | 2 | 2 | 1 | 1 | 42 | 17 | 20 | 13 | 0 |
| 156 | 05/12/2013 | 63 | 3 | 0 | 0 | 2 | 1 | 0 | 1 | 0 |
| 157 | 06/12/2013 | 3 | 1 | 63 | 3 | 0 | 0 | 2 | 1 | 1 |
| 158 | 07/12/2013 | 0 | 0 | 3 | 1 | 63 | 3 | 0 | 0 | 0 |
| 159 | 08/12/2013 | 0 | 0 | 0 | 0 | 3 | 1 | 63 | 3 | 0 |
| 160 | 11/12/2013 | 106 | 15 | 27 | 4 | 0 | 0 | 0 | 0 | 1 |
| 161 | 12/12/2013 | 6 | 3 | 106 | 15 | 27 | 4 | 0 | 0 | 0 |
| 162 | 13/12/2013 | 0 | 0 | 6 | 3 | 106 | 15 | 27 | 4 | 0 |
| 163 | 14/12/2013 | 0 | 0 | 0 | 0 | 6 | 3 | 106 | 15 | 0 |

| Referências | | Atributos/Fatores | | | | | | | | Rótulos |
|-------------|------------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|---------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Classe (Binária) |
| 164 | 14/04/2014 | 95 | 15 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 165 | 15/04/2014 | 25 | 12 | 95 | 15 | 0 | 0 | 0 | 0 | 0 |
| 166 | 16/04/2014 | 10 | 6 | 25 | 12 | 95 | 15 | 0 | 0 | 0 |
| 167 | 17/04/2014 | 0 | 1 | 10 | 6 | 25 | 12 | 95 | 15 | 0 |
| 168 | 19/06/2014 | 36 | 11 | 4 | 2 | 0 | 0 | 0 | 0 | 0 |
| 169 | 20/06/2014 | 0 | 0 | 36 | 11 | 4 | 2 | 0 | 0 | 0 |
| 170 | 21/06/2014 | 0 | 1 | 0 | 0 | 36 | 11 | 4 | 2 | 0 |
| 171 | 22/06/2014 | 0 | 0 | 0 | 1 | 0 | 0 | 36 | 11 | 0 |
| 172 | 11/07/2014 | 33 | 8 | 19 | 6 | 1 | 1 | 12 | 2 | 0 |
| 173 | 12/07/2014 | 5 | 2 | 33 | 8 | 19 | 6 | 1 | 1 | 0 |
| 174 | 13/07/2014 | 0 | 0 | 5 | 2 | 33 | 8 | 19 | 6 | 0 |
| 175 | 14/07/2014 | 0 | 0 | 0 | 0 | 5 | 2 | 33 | 8 | 0 |
| 176 | 01/02/2015 | 32 | 4 | 49 | 5 | 1 | 0 | 0 | 0 | 0 |
| 177 | 02/02/2015 | 4 | 2 | 32 | 4 | 49 | 5 | 1 | 0 | 0 |
| 178 | 03/02/2015 | 4 | 2 | 4 | 2 | 32 | 4 | 49 | 5 | 0 |
| 179 | 04/02/2015 | 1 | 1 | 4 | 2 | 4 | 2 | 32 | 4 | 0 |
| 180 | 22/03/2015 | 61 | 6 | 1 | 1 | 2 | 1 | 3 | 1 | 0 |
| 181 | 23/03/2015 | 21 | 6 | 61 | 6 | 1 | 1 | 2 | 1 | 0 |
| 182 | 24/03/2015 | 4 | 1 | 21 | 6 | 61 | 6 | 1 | 1 | 0 |
| 183 | 25/03/2015 | 0 | 0 | 4 | 1 | 21 | 6 | 61 | 6 | 0 |
| 184 | 01/05/2015 | 0 | 0 | 50 | 8 | 0 | 1 | 0 | 0 | 0 |
| 185 | 02/05/2015 | 0 | 0 | 0 | 0 | 50 | 8 | 0 | 1 | 0 |
| 186 | 03/05/2015 | 0 | 0 | 0 | 0 | 0 | 0 | 50 | 8 | 0 |
| 187 | 19/06/2015 | 84 | 19 | 0 | 0 | 0 | 0 | 6 | 5 | 0 |

| Referências | | Atributos/Fatores | | | | | | | | Rótulos |
|-------------|------------|-------------------------|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|----------------|---------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-48h) | | 3º Intervalo (48-72h) | | 4º Intervalo (72-96h) | | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | Classe (Binária) |
| 188 | 20/06/2015 | 3 | 3 | 84 | 19 | 0 | 0 | 0 | 0 | 0 |
| 189 | 21/06/2015 | 0 | 0 | 3 | 3 | 84 | 19 | 0 | 0 | 0 |
| 190 | 22/06/2015 | 0 | 0 | 0 | 0 | 3 | 3 | 84 | 19 | 0 |
| 191 | 13/09/2015 | 31 | 15 | 26 | 11 | 19 | 6 | 0 | 0 | 0 |
| 192 | 14/09/2015 | 0 | 1 | 31 | 15 | 26 | 11 | 19 | 6 | 0 |
| 193 | 15/09/2015 | 0 | 1 | 0 | 1 | 31 | 15 | 26 | 11 | 0 |

(b) Modulação da Precipitação – MP02

Tabela 68 – Dados de Entrada Classes (0) e (1) – MP02

| Referências | | Atributos/Fatores | | | | | Rótulos |
|-------------|------------|----------------------|-------------|-----------------------|-------------|---------------------------------|------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-96h) | | Fator Distribuição 1º Intervalo | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | (%) | Classe (Binária) |
| 1 | 21/01/2009 | 94 | 12 | 25 | 8 | 60 | 0 |
| 2 | 22/01/2009 | 23 | 9 | 113 | 18 | 15 | 0 |
| 3 | 23/01/2009 | 9 | 6 | 130 | 25 | 6 | 0 |
| 4 | 24/01/2009 | 6 | 5 | 126 | 27 | 4 | 0 |
| 5 | 12/02/2009 | 62 | 6 | 3 | 1 | 98 | 0 |
| 6 | 13/02/2009 | 4 | 4 | 65 | 7 | 6 | 0 |
| 7 | 14/02/2009 | 10 | 4 | 69 | 11 | 16 | 0 |
| 8 | 15/02/2009 | 0 | 0 | 76 | 14 | 0 | 0 |
| 9 | 23/04/2009 | 19 | 4 | 59 | 9 | 12 | 0 |
| 10 | 24/04/2009 | 0 | 0 | 78 | 13 | 0 | 0 |
| 11 | 21/09/2009 | 55 | 9 | 5 | 4 | 56 | 0 |
| 12 | 22/09/2009 | 2 | 2 | 60 | 13 | 2 | 0 |
| 13 | 23/09/2009 | 0 | 0 | 62 | 15 | 0 | 0 |
| 14 | 24/09/2009 | 6 | 5 | 57 | 11 | 6 | 0 |
| 15 | 08/10/2009 | 40 | 16 | 0 | 0 | 41 | 0 |
| 16 | 09/10/2009 | 70 | 16 | 40 | 16 | 71 | 0 |
| 17 | 10/10/2009 | 15 | 8 | 110 | 32 | 15 | 0 |
| 18 | 11/10/2009 | 0 | 0 | 125 | 40 | 0 | 0 |
| 19 | 12/10/2009 | 0 | 0 | 85 | 24 | 0 | 0 |
| 20 | 04/12/2009 | 66 | 15 | 5 | 2 | 47 | 1 |
| 21 | 05/12/2009 | 14 | 9 | 71 | 17 | 10 | 0 |
| 22 | 06/12/2009 | 0 | 0 | 82 | 25 | 0 | 0 |
| 23 | 07/12/2009 | 5 | 2 | 80 | 24 | 4 | 0 |
| 24 | 09/12/2009 | 57 | 9 | 21 | 15 | 41 | 0 |
| 25 | 10/12/2009 | 44 | 10 | 78 | 24 | 31 | 1 |
| 26 | 11/12/2009 | 1 | 1 | 117 | 32 | 1 | 1 |
| 27 | 12/12/2009 | 0 | 0 | 102 | 20 | 0 | 0 |
| 28 | 30/12/2009 | 53 | 10 | 50 | 9 | 38 | 1 |
| 29 | 31/12/2009 | 46 | 13 | 79 | 17 | 33 | 0 |
| 30 | 01/01/2010 | 0 | 0 | 111 | 26 | 0 | 0 |
| 31 | 02/01/2010 | 0 | 0 | 99 | 23 | 0 | 0 |
| 32 | 15/01/2010 | 76 | 10 | 20 | 3 | 49 | 1 |
| 33 | 16/01/2010 | 1 | 1 | 96 | 13 | 1 | 1 |
| 34 | 17/01/2010 | 0 | 0 | 97 | 14 | 0 | 0 |
| 35 | 18/01/2010 | 0 | 0 | 77 | 11 | 0 | 0 |
| 36 | 22/01/2010 | 58 | 5 | 14 | 3 | 37 | 0 |
| 37 | 23/01/2010 | 0 | 0 | 65 | 7 | 0 | 0 |

| Referências | | Atributos/Fatores | | | | | Rótulos |
|-------------|------------|----------------------|-------------|-----------------------|-------------|---------------------------------|------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-96h) | | Fator Distribuição 1º Intervalo | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | (%) | Classe (Binária) |
| 38 | 24/01/2010 | 3 | 1 | 60 | 6 | 2 | 0 |
| 39 | 25/01/2010 | 26 | 6 | 61 | 6 | 17 | 0 |
| 40 | 01/03/2010 | 57 | 19 | 9 | 6 | 37 | 0 |
| 41 | 02/03/2010 | 7 | 6 | 60 | 22 | 4 | 0 |
| 42 | 03/03/2010 | 3 | 2 | 66 | 27 | 2 | 0 |
| 43 | 04/03/2010 | 2 | 2 | 67 | 27 | 1 | 0 |
| 44 | 06/03/2010 | 90 | 5 | 9 | 6 | 58 | 1 |
| 45 | 07/03/2010 | 0 | 0 | 96 | 9 | 0 | 1 |
| 46 | 08/03/2010 | 0 | 0 | 94 | 7 | 0 | 0 |
| 47 | 09/03/2010 | 0 | 0 | 90 | 5 | 0 | 0 |
| 48 | 16/03/2010 | 15 | 6 | 49 | 8 | 10 | 0 |
| 49 | 17/03/2010 | 39 | 9 | 61 | 13 | 25 | 1 |
| 50 | 18/03/2010 | 0 | 0 | 59 | 17 | 0 | 0 |
| 51 | 31/03/2010 | 32 | 7 | 39 | 8 | 21 | 0 |
| 52 | 01/04/2010 | 4 | 3 | 71 | 15 | 2 | 0 |
| 53 | 05/04/2010 | 102 | 9 | 10 | 2 | 63 | 1 |
| 54 | 06/04/2010 | 182 | 21 | 112 | 11 | 112 | 1 |
| 55 | 07/04/2010 | 24 | 7 | 294 | 32 | 15 | 0 |
| 56 | 08/04/2010 | 17 | 5 | 308 | 37 | 10 | 0 |
| 57 | 09/04/2010 | 15 | 4 | 223 | 33 | 9 | 1 |
| 58 | 29/04/2010 | 18 | 9 | 52 | 9 | 11 | 0 |
| 59 | 30/04/2010 | 2 | 1 | 70 | 18 | 1 | 0 |
| 60 | 01/05/2010 | 0 | 0 | 68 | 17 | 0 | 0 |
| 61 | 09/05/2010 | 43 | 14 | 2 | 1 | 36 | 0 |
| 62 | 10/05/2010 | 8 | 3 | 45 | 15 | 7 | 0 |
| 63 | 11/05/2010 | 0 | 0 | 53 | 18 | 0 | 0 |
| 64 | 12/05/2010 | 7 | 1 | 51 | 17 | 6 | 0 |
| 65 | 16/07/2010 | 30 | 9 | 49 | 21 | 36 | 0 |
| 66 | 17/07/2010 | 58 | 14 | 73 | 29 | 69 | 0 |
| 67 | 18/07/2010 | 7 | 3 | 102 | 32 | 8 | 0 |
| 68 | 19/07/2010 | 0 | 0 | 95 | 26 | 0 | 0 |
| 69 | 20/07/2010 | 0 | 0 | 65 | 17 | 0 | 0 |
| 70 | 26/10/2010 | 33 | 8 | 7 | 3 | 34 | 0 |
| 71 | 27/10/2010 | 49 | 5 | 33 | 9 | 50 | 0 |
| 72 | 28/10/2010 | 0 | 0 | 82 | 13 | 0 | 0 |
| 73 | 29/10/2010 | 0 | 0 | 82 | 13 | 0 | 0 |
| 74 | 30/10/2010 | 7 | 1 | 49 | 5 | 7 | 0 |
| 75 | 05/12/2010 | 70 | 4 | 22 | 3 | 50 | 0 |
| 76 | 06/12/2010 | 6 | 2 | 72 | 5 | 4 | 0 |
| 77 | 07/12/2010 | 0 | 1 | 76 | 6 | 0 | 0 |

| Referências | | Atributos/Fatores | | | | | Rótulos |
|-------------|------------|----------------------|-------------|-----------------------|-------------|---------------------------------|------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-96h) | | Fator Distribuição 1º Intervalo | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | (%) | Classe (Binária) |
| 78 | 08/12/2010 | 0 | 0 | 76 | 7 | 0 | 0 |
| 79 | 12/01/2011 | 5 | 1 | 55 | 14 | 3 | 0 |
| 80 | 13/01/2011 | 3 | 1 | 60 | 15 | 2 | 0 |
| 81 | 14/01/2011 | 2 | 1 | 60 | 15 | 1 | 0 |
| 82 | 25/04/2011 | 103 | 4 | 48 | 4 | 64 | 1 |
| 83 | 26/04/2011 | 60 | 8 | 151 | 8 | 37 | 1 |
| 84 | 27/04/2011 | 7 | 3 | 211 | 16 | 4 | 0 |
| 85 | 28/04/2011 | 0 | 1 | 170 | 15 | 0 | 0 |
| 86 | 29/04/2011 | 0 | 0 | 67 | 12 | 0 | 0 |
| 87 | 13/05/2011 | 31 | 7 | 20 | 6 | 26 | 0 |
| 88 | 16/05/2011 | 13 | 5 | 36 | 11 | 11 | 0 |
| 89 | 28/05/2011 | 15 | 5 | 34 | 8 | 13 | 0 |
| 90 | 29/05/2011 | 0 | 1 | 49 | 13 | 0 | 0 |
| 91 | 30/05/2011 | 0 | 0 | 49 | 14 | 0 | 0 |
| 92 | 14/09/2011 | 54 | 14 | 7 | 4 | 55 | 0 |
| 93 | 15/09/2011 | 4 | 3 | 60 | 17 | 4 | 0 |
| 94 | 16/09/2011 | 0 | 0 | 58 | 17 | 0 | 0 |
| 95 | 17/09/2011 | 0 | 0 | 58 | 17 | 0 | 0 |
| 96 | 17/10/2011 | 34 | 14 | 15 | 9 | 35 | 0 |
| 97 | 18/10/2011 | 9 | 4 | 46 | 21 | 9 | 0 |
| 98 | 19/10/2011 | 3 | 2 | 48 | 21 | 3 | 0 |
| 99 | 20/10/2011 | 0 | 0 | 46 | 20 | 0 | 0 |
| 100 | 27/12/2011 | 8 | 3 | 46 | 16 | 6 | 0 |
| 101 | 28/12/2011 | 15 | 5 | 54 | 19 | 11 | 0 |
| 102 | 29/12/2011 | 4 | 2 | 64 | 22 | 3 | 0 |
| 103 | 02/01/2012 | 52 | 17 | 15 | 11 | 33 | 0 |
| 104 | 03/01/2012 | 0 | 0 | 67 | 28 | 0 | 0 |
| 105 | 04/01/2012 | 0 | 0 | 62 | 25 | 0 | 0 |
| 106 | 01/05/2012 | 30 | 10 | 48 | 13 | 25 | 0 |
| 107 | 02/05/2012 | 0 | 1 | 78 | 23 | 0 | 0 |
| 108 | 03/05/2012 | 4 | 2 | 74 | 23 | 3 | 0 |
| 109 | 07/06/2012 | 46 | 8 | 7 | 5 | 52 | 0 |
| 110 | 08/06/2012 | 15 | 7 | 53 | 13 | 17 | 0 |
| 111 | 09/06/2012 | 36 | 13 | 68 | 20 | 40 | 0 |
| 112 | 10/06/2012 | 1 | 1 | 97 | 28 | 1 | 0 |
| 113 | 11/06/2012 | 4 | 2 | 52 | 21 | 4 | 0 |
| 114 | 12/06/2012 | 0 | 0 | 41 | 16 | 0 | 0 |
| 115 | 26/09/2012 | 75 | 15 | 19 | 4 | 76 | 0 |
| 116 | 27/09/2012 | 0 | 0 | 94 | 19 | 0 | 0 |
| 117 | 28/09/2012 | 0 | 0 | 94 | 19 | 0 | 0 |

| Referências | | Atributos/Fatores | | | | | Rótulos |
|-------------|------------|----------------------|-------------|-----------------------|-------------|---------------------------------|------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-96h) | | Fator Distribuição 1º Intervalo | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | (%) | Classe (Binária) |
| 118 | 29/09/2012 | 0 | 0 | 75 | 15 | 0 | 0 |
| 119 | 16/11/2012 | 5 | 2 | 47 | 20 | 4 | 0 |
| 120 | 04/01/2013 | 13 | 5 | 55 | 16 | 8 | 0 |
| 121 | 05/01/2013 | 0 | 0 | 68 | 21 | 0 | 0 |
| 122 | 06/01/2013 | 0 | 0 | 65 | 20 | 0 | 0 |
| 123 | 15/01/2013 | 47 | 3 | 11 | 5 | 30 | 1 |
| 124 | 16/01/2013 | 3 | 2 | 57 | 7 | 2 | 0 |
| 125 | 17/01/2013 | 31 | 4 | 60 | 9 | 20 | 1 |
| 126 | 18/01/2013 | 5 | 2 | 81 | 9 | 3 | 0 |
| 127 | 22/01/2013 | 46 | 6 | 51 | 11 | 29 | 1 |
| 128 | 23/01/2013 | 0 | 0 | 92 | 16 | 0 | 1 |
| 129 | 24/01/2013 | 0 | 0 | 78 | 13 | 0 | 0 |
| 130 | 27/01/2013 | 6 | 3 | 56 | 7 | 4 | 0 |
| 131 | 28/01/2013 | 4 | 3 | 62 | 10 | 3 | 0 |
| 132 | 29/01/2013 | 6 | 6 | 66 | 13 | 4 | 0 |
| 133 | 17/03/2013 | 58 | 7 | 21 | 8 | 37 | 0 |
| 134 | 18/03/2013 | 36 | 9 | 65 | 10 | 23 | 1 |
| 135 | 19/03/2013 | 4 | 3 | 96 | 18 | 3 | 0 |
| 136 | 20/03/2013 | 0 | 1 | 98 | 19 | 0 | 0 |
| 137 | 17/05/2013 | 98 | 15 | 0 | 0 | 82 | 0 |
| 138 | 18/05/2013 | 6 | 5 | 98 | 15 | 5 | 0 |
| 139 | 19/05/2013 | 0 | 1 | 104 | 20 | 0 | 0 |
| 140 | 20/05/2013 | 0 | 0 | 104 | 21 | 0 | 0 |
| 141 | 02/07/2013 | 38 | 9 | 16 | 3 | 45 | 0 |
| 142 | 03/07/2013 | 0 | 0 | 54 | 12 | 0 | 0 |
| 143 | 04/07/2013 | 0 | 0 | 54 | 12 | 0 | 0 |
| 144 | 05/07/2013 | 0 | 0 | 38 | 9 | 0 | 0 |
| 145 | 04/09/2013 | 45 | 15 | 8 | 3 | 45 | 0 |
| 146 | 05/09/2013 | 7 | 3 | 53 | 18 | 7 | 0 |
| 147 | 06/09/2013 | 0 | 0 | 60 | 21 | 0 | 0 |
| 148 | 07/09/2013 | 0 | 0 | 52 | 18 | 0 | 0 |
| 149 | 16/10/2013 | 38 | 14 | 0 | 0 | 39 | 0 |
| 150 | 17/10/2013 | 5 | 2 | 38 | 14 | 5 | 0 |
| 151 | 18/10/2013 | 12 | 3 | 43 | 16 | 12 | 0 |
| 152 | 19/10/2013 | 0 | 0 | 55 | 19 | 0 | 0 |
| 153 | 07/11/2013 | 42 | 17 | 30 | 16 | 33 | 0 |
| 154 | 08/11/2013 | 1 | 1 | 72 | 33 | 1 | 0 |
| 155 | 09/11/2013 | 2 | 2 | 63 | 31 | 2 | 0 |
| 156 | 05/12/2013 | 63 | 3 | 2 | 2 | 45 | 0 |
| 157 | 06/12/2013 | 3 | 1 | 65 | 4 | 2 | 1 |

| Referências | | Atributos/Fatores | | | | | Rótulos |
|-------------|------------|----------------------|-------------|-----------------------|-------------|---------------------------------|------------------|
| | | 1º Intervalo (0-24h) | | 2º Intervalo (24-96h) | | Fator Distribuição 1º Intervalo | |
| Amostra | Dia | Acumulada (mm/24h) | Duração (h) | Acumulada (mm/24h) | Duração (h) | (%) | Classe (Binária) |
| 158 | 07/12/2013 | 0 | 0 | 66 | 4 | 0 | 0 |
| 159 | 08/12/2013 | 0 | 0 | 66 | 4 | 0 | 0 |
| 160 | 11/12/2013 | 106 | 15 | 27 | 4 | 76 | 1 |
| 161 | 12/12/2013 | 6 | 3 | 133 | 19 | 4 | 0 |
| 162 | 13/12/2013 | 0 | 0 | 139 | 22 | 0 | 0 |
| 163 | 14/12/2013 | 0 | 0 | 112 | 18 | 0 | 0 |
| 164 | 14/04/2014 | 95 | 15 | 0 | 0 | 59 | 0 |
| 165 | 15/04/2014 | 25 | 12 | 95 | 15 | 15 | 0 |
| 166 | 16/04/2014 | 10 | 6 | 120 | 27 | 6 | 0 |
| 167 | 17/04/2014 | 0 | 1 | 130 | 33 | 0 | 0 |
| 168 | 19/06/2014 | 36 | 11 | 4 | 2 | 40 | 0 |
| 169 | 20/06/2014 | 0 | 0 | 40 | 13 | 0 | 0 |
| 170 | 21/06/2014 | 0 | 1 | 40 | 13 | 0 | 0 |
| 171 | 22/06/2014 | 0 | 0 | 36 | 12 | 0 | 0 |
| 172 | 11/07/2014 | 33 | 8 | 32 | 9 | 39 | 0 |
| 173 | 12/07/2014 | 5 | 2 | 53 | 15 | 6 | 0 |
| 174 | 13/07/2014 | 0 | 0 | 57 | 16 | 0 | 0 |
| 175 | 14/07/2014 | 0 | 0 | 38 | 10 | 0 | 0 |
| 176 | 01/02/2015 | 32 | 4 | 50 | 5 | 51 | 0 |
| 177 | 02/02/2015 | 4 | 2 | 82 | 9 | 6 | 0 |
| 178 | 03/02/2015 | 4 | 2 | 85 | 11 | 6 | 0 |
| 179 | 04/02/2015 | 1 | 1 | 40 | 8 | 2 | 0 |
| 180 | 22/03/2015 | 61 | 6 | 6 | 3 | 39 | 0 |
| 181 | 23/03/2015 | 21 | 6 | 64 | 8 | 13 | 0 |
| 182 | 24/03/2015 | 4 | 1 | 83 | 13 | 3 | 0 |
| 183 | 25/03/2015 | 0 | 0 | 86 | 13 | 0 | 0 |
| 184 | 01/05/2015 | 0 | 0 | 50 | 9 | 0 | 0 |
| 185 | 02/05/2015 | 0 | 0 | 50 | 9 | 0 | 0 |
| 186 | 03/05/2015 | 0 | 0 | 50 | 8 | 0 | 0 |
| 187 | 19/06/2015 | 84 | 19 | 6 | 5 | 94 | 0 |
| 188 | 20/06/2015 | 3 | 3 | 84 | 19 | 3 | 0 |
| 189 | 21/06/2015 | 0 | 0 | 87 | 22 | 0 | 0 |
| 190 | 22/06/2015 | 0 | 0 | 87 | 22 | 0 | 0 |
| 191 | 13/09/2015 | 31 | 15 | 45 | 17 | 31 | 0 |
| 192 | 14/09/2015 | 0 | 1 | 76 | 32 | 0 | 0 |
| 193 | 15/09/2015 | 0 | 1 | 57 | 27 | 0 | 0 |

APÊNDICE B – PRECIPITAÇÃO COM E SEM MOVIMENTOS DE MASSA

(a) Estações Pluviométricas

Tabela 69 – Precipitação da Estação Alto da Boa Vista- 2009 a 2015

| Acumulada diária (mm) | Duração (h) | | | | | | | | | | | |
|-----------------------|------------------|-----|------|-------|-------|------|--------------------------------|-----|------|-------|-------|-------|
| | Todos os eventos | | | | | | Eventos com movimento de massa | | | | | |
| | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 0-24 | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 20-24 |
| 0-20 | 551 | 122 | 18 | 3 | - | - | 1 | - | - | - | - | - |
| 20-40 | 22 | 36 | 32 | 13 | 4 | - | - | - | - | - | - | - |
| 40-60 | 2 | 9 | 11 | 11 | 9 | 1 | - | - | - | - | - | - |
| 60-80 | - | 4 | 2 | 3 | 2 | 1 | - | - | - | - | - | - |
| 80-100 | 1 | 2 | - | 2 | 1 | - | - | - | - | - | - | - |
| 100-120 | - | - | 2 | 1 | - | 1 | - | - | - | - | - | - |
| 120-140 | - | 1 | 1 | - | 1 | 1 | - | - | - | - | - | - |
| 140-160 | - | - | - | - | - | - | - | - | - | - | - | - |
| 160-180 | - | - | - | - | - | - | - | - | - | - | - | - |
| 180-200 | - | - | - | 1 | 1 | 1 | - | - | - | - | - | 1 |
| 200-220 | - | - | - | - | - | - | - | - | - | - | - | - |
| Total | 873 | | | | | | 2 | | | | | |

Tabela 70 – Precipitação da Estação Grajaú - 2009 a 2015

| Acumulada diária (mm) | Duração (h) | | | | | | | | | | | |
|-----------------------|------------------|-----|------|-------|-------|------|--------------------------------|-----|------|-------|-------|-------|
| | Todos os eventos | | | | | | Eventos com movimento de massa | | | | | |
| | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 0-24 | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 20-24 |
| 0-20 | 653 | 115 | 17 | 1 | - | - | 2 | - | - | - | - | - |
| 20-40 | 23 | 36 | 10 | 6 | 1 | - | - | - | 2 | - | - | - |
| 40-60 | 9 | 11 | 5 | 3 | 4 | - | - | - | - | - | - | - |
| 60-80 | 1 | 2 | 3 | 1 | 1 | - | - | - | - | - | - | - |
| 80-100 | - | 2 | 2 | - | - | - | - | - | - | - | - | - |
| 100-120 | 1 | - | 1 | 1 | - | - | - | - | 1 | - | - | - |
| 120-140 | - | - | - | - | - | - | - | - | - | - | - | - |
| 140-160 | - | - | - | - | 1 | - | - | - | - | - | 1 | - |
| 160-180 | - | - | - | - | - | - | - | - | - | - | - | - |
| 180-200 | - | - | - | - | - | - | - | - | - | - | - | - |
| 200-220 | - | - | - | - | - | - | - | - | - | - | - | - |
| Total | 910 | | | | | | 6 | | | | | |

Tabela 71 – Precipitação da Estação Laranjeiras - 2009 a 2015

| Acumulada diária (mm) | Duração (h) | | | | | | | | | | | |
|-----------------------|------------------|-----|------|-------|-------|------|--------------------------------|-----|------|-------|-------|-------|
| | Todos os eventos | | | | | | Eventos com movimento de massa | | | | | |
| | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 0-24 | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 20-24 |
| 0-20 | 664 | 109 | 17 | 2 | 0 | 0 | - | - | - | - | - | - |
| 20-40 | 16 | 33 | 20 | 10 | 1 | 0 | - | - | - | - | - | - |
| 40-60 | 3 | 6 | 6 | 5 | 2 | 0 | - | - | - | - | - | - |
| 60-80 | 0 | 3 | 2 | 4 | 1 | 1 | - | - | - | - | - | - |
| 80-100 | 1 | 1 | 1 | 1 | 0 | 0 | - | - | 1 | - | - | - |
| 100-120 | 0 | 0 | 0 | 0 | 0 | 0 | - | - | - | - | - | - |
| 120-140 | 0 | 0 | 0 | 0 | 0 | 0 | - | - | - | - | - | - |
| 140-160 | 0 | 0 | 0 | 0 | 0 | 0 | - | - | - | - | - | - |
| 160-180 | 0 | 0 | 0 | 0 | 0 | 0 | - | - | - | - | - | - |
| 180-200 | 0 | 0 | 0 | 0 | 0 | 1 | - | - | - | - | - | 1 |
| 200-220 | 0 | 0 | 0 | 0 | 0 | 0 | - | - | - | - | - | - |
| Total | 910 | | | | | | 2 | | | | | |

Tabela 72 – Precipitação da Estação Santa Teresa - 2009 a 2015

| Acumulada diária (mm) | Duração (h) | | | | | | | | | | | |
|-----------------------|------------------|-----|------|-------|-------|------|--------------------------------|-----|------|-------|-------|-------|
| | Todos os eventos | | | | | | Eventos com movimento de massa | | | | | |
| | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 0-24 | 0-4 | 4-8 | 8-12 | 12-16 | 16-20 | 20-24 |
| 0-20 | 662 | 122 | 20 | 2 | - | - | 1 | - | - | - | - | - |
| 20-40 | 16 | 36 | 17 | 10 | 1 | - | 1 | - | 1 | - | - | - |
| 40-60 | 1 | 5 | 6 | 6 | 3 | - | - | - | 1 | - | - | - |
| 60-80 | - | 4 | 2 | 5 | 1 | 1 | - | 1 | - | 1 | - | - |
| 80-100 | - | 1 | 1 | 2 | 1 | - | - | 1 | 1 | - | - | - |
| 100-120 | 1 | - | - | - | - | - | - | - | - | - | - | - |
| 120-140 | - | - | - | - | - | - | - | - | - | - | - | - |
| 140-160 | - | - | - | - | - | - | - | - | - | - | - | - |
| 160-180 | - | - | - | - | - | - | - | - | - | - | - | - |
| 180-200 | - | - | - | - | - | 1 | - | - | - | - | - | 1 |
| 200-220 | - | - | - | - | - | - | - | - | - | - | - | - |
| Total | 927 | | | | | | 9 | | | | | |

APÊNDICE C – RESULTADOS CLASSES DESBALANCEADAS

(a) Floresta Aleatória: Modulação Temporal – MP02

Para fins de comparação entre os resultados de classes desbalanceadas e balanceadas, foram utilizados os hiperparâmetros do modelo 1 da Tabela 49. Desta forma, na Tabela 73, estão compilados os resultados das métricas de desempenho de treinamento, validação e de teste, para classes desbalanceadas, referente ao limiar padrão em 0,5 adotado pela biblioteca Scikit-Learn (2007).

Tabela 73. Floresta Aleatória – MP02: Classes Desbalanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,89 | 0,90 | 0,90 |
| <i>AUROC</i> | 0,91 | 0,81 | 0,49 |
| Precisão | 0,20 | 0,00 | 0,00 |
| Sensibilidade | 0,03 | 0,00 | 0,00 |
| Erro | 0,23 | 0,27 | 0,34 |

I. Quanto ao Treinamento e à Validação

A apresentação das métricas de treinamento objetiva explicitar a resposta de aderência do algoritmo em relação aos dados utilizados para treinamento. Como se pode observar na Tabela 73, as métricas de treinamento acurácia e *AUROC* são maiores do que 0,8 e estão próximas ao valor máximo, que é 1,0 (um). Entretanto, precisão e sensibilidade são iguais ou inferiores a 0,2. A sensibilidade, por exemplo é praticamente zero, entende-se que principalmente em função do fato de que há apenas 10% de amostras da classe (1).

De modo geral, a interpretação da métrica de treinamento é que o algoritmo é capaz de classificar corretamente os dados de treinamento. Entretanto, neste caso as baixas sensibilidade e precisão no treinamento, analisadas conjuntamente com o erro e a *AUROC*, indicam que as distribuições probabilística dos dados de treinamento e, também, de validação, não estão ocorrendo ao longo do espaço 0 a 1, mas sim, provavelmente, estão concentradas em parte do trecho de 0 a 0,5.

Comparando-se as diferenças entre as métricas de treinamento com as de validação, observa-se que o erro na validação é aumentado e, também, precisão e sensibilidade se tornam zero. Sendo assim, visto que as *AUROC*, no treinamento e na validação são respectivamente, 0,91 e 0,81, este fato reforça a interpretação de que as distribuições probabilística estão ocorrendo no trecho de 0 a 0,5.

Ainda, na Tabela 73, identifica-se que as métricas acurácia de treinamento, validação e teste das classes desbalanceadas, convergem para o valor 0,9. Neste caso, deve-se atentar para o fato de que o modelo se torna tendencioso em classificar a classe (0), que é majoritária, fato que resulta em um valor de acurácia próximo ou igual a 1,0.

Sendo assim, caracteriza-se a necessidade de utilização de outras métricas, além da acurácia, tal como *AUROC* e erro, para uma melhor análise da capacidade de generalização do modelo. Os resultados de *AUROC* do treinamento e da validação estão acima da referência de 0,7 (item 2.4.2). Entretanto, o erro limite de referência, para um conjunto cuja classe (1) é representada por 10% de amostras, é 0,14. Sendo assim, tanto no treinamento quanto na validação este valor limite foi extrapolado.

II. Quanto ao Teste

Em termos de classes desbalanceadas (Tabela 73), as métricas das amostras de teste, principalmente *AUROC* e erro, indicam que o modelo, para amostras com as quais nunca teve contato, não é capaz de realizar boas previsões em relação a classe (1). Logo, ele não consegue prever a ocorrência de movimentos de massa.

Ainda, a convergência da métrica acurácia na validação e no teste para classes desbalanceadas corrobora com o fato de que o modelo é capaz de classificar principalmente eventos pertencentes à classe (0). A maioria das amostras dos grupos de treinamento e de validação pertencem à classe (0). Desta forma, no treinamento, o modelo possui maior contato com amostras de rótulo (0) e desenvolve forte tendência a classificar eventos em classe (0). Como na validação e no teste a maior parte das amostras também pertencem à classe (0), ele é bem-sucedido nas previsões desta classe e obtém acurácia de 90%.

(b) Máquina de Vetores-Suporte: Modulação Temporal – MP01

Para fins de comparação entre os resultados de classes desbalanceadas e balanceadas, foram utilizados os hiperparâmetros do modelo 1 da Tabela 52. Desta forma, na Tabela 74, estão compilados os resultados das métricas de desempenho de treinamento, validação e de teste, para classes desbalanceadas, referente ao limiar padrão em 0,5 adotado pela biblioteca Scikit-Learn (2007).

Tabela 74. Máquina de Vetores-Suporte – MP01: Classes Desbalanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,90 | 0,90 | 0,90 |
| AUROC | 0,99 | 0,71 | 0,48 |
| Precisão | 0,00 | 0,00 | 0,00 |
| Sensibilidade | 0,00 | 0,00 | 0,00 |
| Erro | 0,18 | 0,31 | 0,34 |

I. Quanto ao Treinamento e à Validação

A apresentação das métricas de treinamento objetiva explicitar a resposta de aderência do algoritmo em relação aos dados utilizados para treinamento. Como se pode observar na Tabela 74, as métricas de treinamento acurácia e *AUROC* são maiores ou iguais a 0,9 e estão próximas ao valor máximo, que é 1,0 (um). Entretanto, precisão e sensibilidade são zero, entende-se que principalmente em função do fato de que há apenas 10% de amostras da classe (1).

De modo geral, a interpretação da métrica de treinamento é que o algoritmo é capaz de classificar corretamente os dados de treinamento. Entretanto, neste caso as baixas sensibilidade e precisão no treinamento, analisadas conjuntamente com o erro e a *AUROC*, indicam que as distribuições probabilística dos dados de treinamento e, também, de validação, não estão ocorrendo ao longo do espaço 0 a 1, mas sim, provavelmente, estão concentradas em parte do trecho de 0 a 0,5.

Comparando-se as diferenças entre as métricas *AUROC* de treinamento com as de validação, observa-se, também, que o erro na validação é aumentado. Sendo assim, pode-se interpretar que, além de as distribuições probabilística não estarem ocorrendo ao longo do espaço 0 a 1, a validação evidencia a dificuldade de o modelo realizar predição de classes.

Ainda, na Tabela 74, identifica-se que as métricas acurácia de treinamento, validação e teste das classes desbalanceadas, convergem para o valor 0,9. Neste caso, deve-se atentar para o fato de que o modelo se torna tendencioso em classificar

a classe (0), que é majoritária, fato que resulta em um valor de acurácia próximo ou igual a 1,0.

Sendo assim, caracteriza-se a necessidade de utilização de outras métricas, além da acurácia, tal como *AUROC* e erro, para uma melhor análise da capacidade de generalização do modelo. Os resultados de *AUROC* do treinamento e da validação estão acima da referência de 0,7 (item 2.4.2). Entretanto, o erro limite de referência, para um conjunto cuja classe (1) é representada por 10% de amostras, é 0,14. Sendo assim, tanto no treinamento quanto na validação este valor limite foi extrapolado.

II. Quanto ao Teste

Em termos de classes desbalanceadas (Tabela 74), as métricas das amostras de teste, principalmente *AUROC* e erro, indicam que o modelo, para amostras com as quais nunca teve contato, não é capaz de realizar boas previsões em relação a classe (1). Logo, ele não consegue prever a ocorrência de movimentos de massa.

Ainda, a convergência da métrica acurácia na validação e no teste para classes desbalanceadas corrobora com o fato de que o modelo é capaz de classificar principalmente eventos pertencentes à classe (0). A maioria das amostras dos grupos de treinamento e de validação pertencem à classe (0). Desta forma, no treinamento, o modelo possui maior contato com amostras de rótulo (0) e desenvolve forte tendência a classificar eventos em classe (0). Como na validação e no teste a maior parte das amostras também pertencem à classe (0), ele é bem-sucedido nas previsões desta classe e obtém acurácia de 90%.

(c) Máquina de Vetores-Suporte: Modulação Temporal – MP02

Para fins de comparação entre os resultados de classes desbalanceadas e balanceadas, foram utilizados os hiperparâmetros do modelo 1 da Tabela 55. Desta forma, na Tabela 75, estão compilados os resultados das métricas de desempenho de treinamento, validação e de teste, para classes desbalanceadas, referente ao limiar padrão em 0,5 adotado pela biblioteca Scikit-Learn (2007).

Tabela 75. Máquina de Vetores-Suporte – MP02: Classes Desbalanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,90 | 0,90 | 0,90 |
| <i>AUROC</i> | 0,98 | 0,71 | 0,45 |
| Precisão | 0,60 | 0,00 | 0,00 |
| Sensibilidade | 0,13 | 0,00 | 0,00 |
| Erro | 0,19 | 0,30 | 0,34 |

I. Quanto ao Treinamento e à Validação

A apresentação das métricas de treinamento objetiva explicitar a resposta de aderência do algoritmo em relação aos dados utilizados para treinamento. Como se pode observar na Tabela 75, as métricas de treinamento acurácia e *AUROC* são maiores ou iguais a 0,9 e estão próximas ao valor máximo, que é 1,0 (um). Entretanto, precisão e sensibilidade são iguais ou inferiores a 0,6. A sensibilidade, por exemplo está próxima de zero, entende-se que principalmente em função do fato de que há apenas 10% de amostras da classe (1).

De modo geral, a interpretação da métrica de treinamento é que o algoritmo é capaz de classificar corretamente os dados de treinamento. Entretanto, neste caso as baixas sensibilidade e precisão no treinamento, analisadas conjuntamente com o erro e a *AUROC*, indicam que as distribuições probabilística dos dados de treinamento e, também, de validação, não estão ocorrendo ao longo do espaço 0 a 1, mas sim, provavelmente, estão concentradas em parte do trecho de 0 a 0,5.

Comparando-se as diferenças entre as métricas de treinamento com as de validação, observa-se que o erro na validação é aumentado e, também, precisão e sensibilidade se tornam zero. Sendo assim, visto que as *AUROC*, no treinamento e na validação são respectivamente, 0,98 e 0,71, este fato reforça a interpretação de que as distribuições probabilística estão ocorrendo no trecho de 0 a 0,5.

Ainda, na Tabela 75, identifica-se que as métricas acurácia de treinamento, validação e teste das classes desbalanceadas, convergem para o valor 0,9. Neste

caso, deve-se atentar para o fato de que o modelo se torna tendencioso em classificar a classe (0), que é majoritária, fato que resulta em um valor de acurácia próximo ou igual a 1,0.

Sendo assim, caracteriza-se a necessidade de utilização de outras métricas, além da acurácia, tal como *AUROC* e erro, para uma melhor análise da capacidade de generalização do modelo. Os resultados de *AUROC* do treinamento e da validação estão acima da referência de 0,7 (item 2.4.2). Entretanto, o erro limite de referência, para um conjunto cuja classe (1) é representada por 10% de amostras, é 0,14. Sendo assim, tanto no treinamento quanto na validação este valor limite foi extrapolado.

II. Quanto ao Teste

Em termos de classes desbalanceadas (Tabela 75), as métricas das amostras de teste, principalmente *AUROC* e erro, indicam que o modelo, para amostras com as quais nunca teve contato, não é capaz de realizar boas previsões em relação a classe (1). Logo, ele não consegue prever a ocorrência de movimentos de massa.

Ainda, a convergência da métrica acurácia na validação e no teste para classes desbalanceadas corrobora com o fato de que o modelo é capaz de classificar principalmente eventos pertencentes à classe (0). A maioria das amostras dos grupos de treinamento e de validação pertencem à classe (0). Desta forma, no treinamento, o modelo possui maior contato com amostras de rótulo (0) e desenvolve forte tendência a classificar eventos em classe (0). Como na validação e no teste a maior parte das amostras também pertencem à classe (0), ele é bem-sucedido nas previsões desta classe e obtém acurácia de 90%.

(d) Perceptron Multicamadas: Modulação Temporal – MP01

Para fins de comparação entre os resultados de classes desbalanceadas e balanceadas, foram utilizados os hiperparâmetros do modelo 1 da Tabela 58. Desta forma, na Tabela 76, estão compilados os resultados das métricas de desempenho de treinamento, validação e de teste, para classes desbalanceadas, referente ao limiar padrão em 0,5 adotado pela biblioteca Scikit-Learn (2007).

Tabela 76. Perceptron Multicamadas – MP01: Classes Desbalanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,89 | 0,92 | 0,90 |
| AUROC | 0,84 | 0,84 | 0,55 |
| Precisão | 0,80 | 0,33 | 0,00 |
| Sensibilidade | 0,06 | 0,20 | 0,00 |
| Erro | 0,29 | 0,26 | 0,34 |

I. Quanto ao Treinamento e à Validação

A apresentação das métricas de treinamento objetiva explicitar a resposta de aderência do algoritmo em relação aos dados utilizados para treinamento. Como se pode observar na Tabela 76, as métricas de treinamento acurácia, AUROC e precisão são maiores ou iguais a 0,8 e estão próximas ao valor máximo, que é 1,0 (um). Entretanto, sensibilidade é praticamente zero, entende-se que principalmente em função do fato de que há apenas 10% de amostras da classe (1).

De modo geral, a interpretação da métrica de treinamento é que o algoritmo é capaz de classificar corretamente os dados de treinamento. Entretanto, neste caso a baixa sensibilidade no treinamento, analisada conjuntamente com o erro e a AUROC, indicam que as distribuições probabilística dos dados de treinamento e, também, de validação, não estão ocorrendo ao longo do espaço 0 a 1, mas sim, provavelmente, estão concentradas em parte do trecho de 0 a 0,5.

Comparando-se as diferenças entre as métricas AUROC, precisão e sensibilidade de treinamento com as de validação, observa-se, também, que o erro na validação é levemente reduzido. Sendo assim, pode-se interpretar que, na validação, houve uma distribuição probabilística melhor do que no treinamento. Embora, a validação evidencie a dificuldade de o modelo realizar predição de classes.

Ainda, na Tabela 74, identifica-se que as métricas acurácia de treinamento, validação e teste das classes desbalanceadas, convergem para o valor 0,9. Neste caso, deve-se atentar para o fato de que o modelo se torna tendencioso em classificar

a classe (0), que é majoritária, fato que resulta em um valor de acurácia próximo ou igual a 1,0.

Sendo assim, caracteriza-se a necessidade de utilização de outras métricas, além da acurácia, tal como *AUROC* e erro, para uma melhor análise da capacidade de generalização do modelo. Os resultados de *AUROC* do treinamento e da validação estão acima da referência de 0,7 (item 2.4.2). Entretanto, o erro limite de referência, para um conjunto cuja classe (1) é representada por 10% de amostras, é 0,14. Sendo assim, tanto no treinamento quanto na validação este valor limite foi extrapolado.

II. Quanto ao Teste

Em termos de classes desbalanceadas (Tabela 76), as métricas das amostras de teste, principalmente *AUROC* e erro, indicam que o modelo, para amostras com as quais nunca teve contato, não é capaz de realizar boas previsões em relação a classe (1). Logo, ele não consegue prever a ocorrência de movimentos de massa.

Ainda, a convergência da métrica acurácia na validação e no teste para classes desbalanceadas corrobora com o fato de que o modelo é capaz de classificar principalmente eventos pertencentes à classe (0). A maioria das amostras dos grupos de treinamento e de validação pertencem à classe (0). Desta forma, no treinamento, o modelo possui maior contato com amostras de rótulo (0) e desenvolve forte tendência a classificar eventos em classe (0). Como na validação e no teste a maior parte das amostras também pertencem à classe (0), ele é bem-sucedido nas previsões desta classe e obtém acurácia de 90%.

(e) Perceptron Multicamadas: Modulação Temporal – MP02

Para fins de comparação entre os resultados de classes desbalanceadas e balanceadas, foram utilizados os hiperparâmetros do modelo 1 da Tabela 61. Desta forma, na Tabela 77, estão compilados os resultados das métricas de desempenho de treinamento, validação e de teste, para classes desbalanceadas, referente ao limiar padrão em 0,5 adotado pela biblioteca Scikit-Learn (2007).

Tabela 77. Perceptron Multicamadas – MP02: Classes Desbalanceadas e Limiar Padrão

| Métricas | Treinamento | Validação | Teste |
|---------------|-------------|-----------|-------|
| Acurácia | 0,90 | 0,90 | 0,90 |
| AUROC | 0,85 | 0,84 | 0,39 |
| Precisão | 0,52 | 0,45 | 0,00 |
| Sensibilidade | 0,31 | 0,47 | 0,00 |
| Erro | 0,30 | 0,27 | 0,34 |

I. Quanto ao Treinamento e à Validação

A apresentação das métricas de treinamento objetiva explicitar a resposta de aderência do algoritmo em relação aos dados utilizados para treinamento. Como se pode observar na Tabela 77, as métricas de treinamento acurácia e AUROC são maiores do que 0,8 e estão próximas ao valor máximo, que é 1,0 (um). Entretanto, precisão e sensibilidade são iguais ou inferiores a 0,52.

De modo geral, a interpretação da métrica de treinamento é que o algoritmo é capaz de classificar corretamente os dados de treinamento. Entretanto, neste caso as baixas sensibilidade e precisão no treinamento, analisadas conjuntamente com o erro e a AUROC, indicam que as distribuições probabilística dos dados de treinamento e, também, de validação, não estão ocorrendo ao longo do espaço 0 a 1, mas sim, provavelmente, estão concentradas em parte do trecho de 0 a 0,5.

Comparando-se as diferenças entre as métricas de treinamento com as de validação, observa-se que o erro na validação é reduzido, enquanto o valor de sensibilidade aumenta. Sendo assim, visto que as AUROC, no treinamento e na validação são praticamente iguais, interpreta-se que a distribuição probabilística da validação foi um pouco melhor do que a do treinamento.

Ainda, na Tabela 77, identifica-se que as métricas acurácia de treinamento, validação e teste das classes desbalanceadas, convergem para o valor 0,9. Neste caso, deve-se atentar para o fato de que o modelo se torna tendencioso em classificar

a classe (0), que é majoritária, fato que resulta em um valor de acurácia próximo ou igual a 1,0.

Sendo assim, caracteriza-se a necessidade de utilização de outras métricas, além da acurácia, tal como *AUROC* e erro, para uma melhor análise da capacidade de generalização do modelo. Os resultados de *AUROC* do treinamento e da validação estão acima da referência de 0,7 (item 2.4.2). Entretanto, o erro limite de referência, para um conjunto cuja classe (1) é representada por 10% de amostras, é 0,14. Sendo assim, tanto no treinamento quanto na validação este valor limite foi extrapolado.

II. Quanto ao Teste

Em termos de classes desbalanceadas (Tabela 77), as métricas das amostras de teste, principalmente *AUROC* e erro, indicam que o modelo, para amostras com as quais nunca teve contato, não é capaz de realizar boas previsões em relação a classe (1). Logo, ele não consegue prever a ocorrência de movimentos de massa.

Ainda, a convergência da métrica acurácia na validação e no teste para classes desbalanceadas corrobora com o fato de que o modelo é capaz de classificar principalmente eventos pertencentes à classe (0). A maioria das amostras dos grupos de treinamento e de validação pertencem à classe (0). Desta forma, no treinamento, o modelo possui maior contato com amostras de rótulo (0) e desenvolve forte tendência a classificar eventos em classe (0). Como na validação e no teste a maior parte das amostras também pertencem à classe (0), ele é bem-sucedido nas previsões desta classe e obtém acurácia de 90%.