


**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
FACULDADE DE ENGENHARIA – CAMPUS DE ILHA SOLTEIRA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**PAULA ANDREA MONTENEGRO CHAUCANES**

**Uso de Autoencoders como técnica de Caracterização e  
auxílio na Classificação de sismos vulcânicos**

Ilha Solteira - SP  
2023



PAULA ANDREA MONTENEGRO CHAUCANES

# **Uso de Autoencoders como técnica de Caracterização e auxilio na Classificação de sismos vulcânicos**

Tese apresentada à Faculdade de Engenharia do Campus de Ilha Solteira - UNESP como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica.

Especialidade: Automação.

Prof.<sup>a</sup>Dra. Anna Diva Plasencia Lotufo  
Orientadora

Ilha Solteira - SP  
2023

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

C496u      Chaucanes, Paula Andrea Montenegro.  
            Uso de Autoencoders como técnica de caracterização e auxílio na  
            classificação de sismos vulcânicos / Paula Andrea Montenegro Chaucanes. --  
            Ilha Solteira: [s.n.], 2023  
            133 f. : il.

            Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia  
            de Ilha Solteira. Área de conhecimento: Automação, 2023

            Orientador: Anna Diva Plasencia Lotufo

            Inclui bibliografia

            1. Redes neurais artificiais. 2. Parametrização. 3. Sinais sísmicos. 4.  
            Processamento digital de sinais. 5. Sismologia vulcânica.

  
**Amanda Sertori dos Santos**  
Bibliotecária - CRB/8-9061  
Seção Técnica de Referência, Atendimento ao  
Usuário e Documentação  
Diretoria Técnica de Biblioteca e Documentação



**UNIVERSIDADE ESTADUAL PAULISTA**

**Câmpus de Ilha Solteira**

**CERTIFICADO DE APROVAÇÃO**

**TÍTULO DA TESE:** USO DE "AUTOENCODERS" COMO TÉCNICA DE CARACTERIZAÇÃO E AUXÍLIO NA CLASSIFICAÇÃO DE SISMOS VULCÂNICOS

**AUTORA:** PAULA ANDREA MONTENEGRO CHAUCANES

**ORIENTADORA:** ANNA DIVA PLASENCIA LOTUFO

Aprovada como parte das exigências para obtenção do Título de Doutora em Engenharia Elétrica,  
área: Automação pela Comissão Examinadora:

Documento assinado digitalmente  
**ANNA DIVA PLASENCIA LOTUFO**  
Data: 19/01/2024 14:28:38 -0300  
Verifique em <https://validar.itd.gov.br>

Profa. Dra. ANNA DIVA PLASENCIA LOTUFO (Participação Presencial)  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Profa. Dra. MARA LUCIA MARTINS LOPES (Participação Presencial)  
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. JOZUE VIEIRA FILHO (Participação Virtual)  
Departamento de Engenharia Eletrônica e de Telecomunicações / Faculdade de Engenharia - UNESP

Prof. Dr. KENJI NOSE FILHO (Participação Virtual)  
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas / Universidade Federal do ABC - UFABC

Dr. SERGIO GAMMALDI (Participação Virtual)  
Osservatorio Etneo, Catania / Istituto Nazionale di Geofisica e Vulcanologia

Ilha Solteira, 15 de dezembro de 2023



*Dedico este trabalho à minha família. Aos meus pais, fonte de inspiração e apoio constante.  
Às minhas irmãs, meu alicerce e companheiras inseparáveis. Seu amor e apoio constante tornaram possível este percurso acadêmico, e por isso expresso minha profunda gratidão.*

## **AGRADECIMENTOS**

Agradeço em primeiro lugar à Deus, por me permitir realizar esse sonho e me dar forças diariamente para superar todos os obstáculos.

Aos meus pais, Braulio e Rosa, e às minhas irmãs Carmen e Carolina, dedico minha eterna gratidão pelo constante incentivo e apoio, sempre torcendo pelo meu sucesso. Expresso também minha gratidão a familiares e amigos que dedicaram suas orações e apoio nessa jornada.

À minha orientadora, Prof.<sup>a</sup> Dra. Anna Diva Plasencia Lotufo, expresso minha profunda gratidão pela imensa oportunidade concedida e por acreditar em minha capacidade. Agradeço pelo constante apoio e por guiar-me na direção correta ao longo deste processo. Não encontro palavras suficientes para expressar minha gratidão. Também estendo meus agradecimentos aos professores do laboratório SINTEL pelo incentivo e pelas valiosas contribuições.

Aos meus amigos e colegas, especialmente a Reginaldo, Andréia B. e Andréia S., expresso minha sincera gratidão pela amizade valiosa e calorosa, pelo constante apoio e pelo compartilhamento de conhecimentos. Agradeço de coração.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, pelo apoio financeiro.

Enfim agradeço a todas as pessoas que direta ou indiretamente me incentivaram a chegar até aqui, a todos vocês o meu respeito, carinho e gratidão.

*O Senhor olha para a terra, e ela treme;  
toca nas montanhas, e elas soltam fumaça.*

**Salmo 104. 32**

## RESUMO

O monitoramento vulcânico é importante na mitigação e prevenção de riscos de erupções, sendo necessária a identificação das fontes internas que geram esse tipo de eventos, bem como a compreensão da dinâmica interna dos vulcões. A sismologia desempenha um papel fundamental no monitoramento vulcânico, mediante a análise de registros dos sinais de sismos gerados nos vulcões. Entretanto, as bases de dados dos observatórios vulcânicos, frequentemente apresentam um desbalanceamento na distribuição dos tipos de sinais sísmicos, devido à prevalência de certos tipos de atividades vulcânicas. Além disso, a alta dimensionalidade de cada evento sísmico torna dispendiosa a análise automática e a classificação destes sinais. Este trabalho de pesquisa aborda desafios como o desbalanceamento de classes e a alta dimensionalidade dos dados sísmicos. Propõe-se o uso de um *Autoencoder* Dual de características (DAF) para caracterização dos sinais, visando obter representações compactas dos sinais para garantir maior definição das classes. O objetivo é contribuir na classificação dos sinais por meio de um modelo de rede neural *Multi Layer Perceptron* (MLP). A técnica de caracterização proposta, DAF, é comparada com métodos convencionais como são LPC (*Linear Predictive Coding*), LFCC (*Lineal Frequency Cepstral Coefficient*) e PCA (*Principal Component Analysis*), com base em uma base de dados de sinais de sismos vulcânicos do vulcão Galeras. Adicionalmente, foram realizados testes com dados externos do vulcão Etna e vulcão Volcano para avaliar a técnica de caracterização e o modelo de classificação proposto.

**Palavras-chave:** redes neurais artificiais; parametrização; sinais sísmicos; processamento digital de sinais; sismologia vulcânica.

## ABSTRACT

Volcanic monitoring is important in mitigating and preventing the risk of eruptions, and it is necessary to identify the internal sources that generate this type of event, as well as to understand the internal dynamics of volcanoes. Seismology plays a fundamental role in volcanic monitoring by analyzing the records of earthquake signals generated by volcanoes. However, volcanic observatory databases often show an imbalance in the distribution of seismic signal types, due to the prevalence of certain types of volcanic activity. In addition, the high dimensionality of each seismic event makes it expensive to automatically analyze and classify these signals. This research work addresses challenges such as class imbalance and the high dimensionality of seismic data. It proposes the use of a Dual Feature Autoencoder (DAF) to characterize the signals, with the aim of obtaining compact representations of the signals to ensure greater class definition. The aim is to help classify signals using a *Multi Layer Perceptron* (MLP), neural network model. The proposed characterization technique, DAF, is compared with conventional methods such as LPC, LFCC and PCA, based on a database of volcanic earthquake signals from the Galeras volcano. In addition, an external validation was carried out with data from the Etna volcano and Volcano to evaluate the characterization technique and the proposed classification model.

**Keywords:** Artificial Neural Networks (ANN); parameterization; seismic signals; digital signal processing; volcanic seismology.

## LISTA DE FIGURAS

|           |                                                                                                             |    |
|-----------|-------------------------------------------------------------------------------------------------------------|----|
| Figura 1  | Localização vulcão Galeras . . . . .                                                                        | 19 |
| Figura 2  | Rede monitoramento sísmico Galeras . . . . .                                                                | 21 |
| Figura 3  | Localização de vulcões na Itália . . . . .                                                                  | 22 |
| Figura 4  | Rede de monitoramento sísmico do INGV-OE . . . . .                                                          | 22 |
| Figura 5  | Registro de evento sísmico VT do vulcão Galeras durante o período<br>2006-2010 . . . . .                    | 26 |
| Figura 6  | Registro de evento sísmico LP do vulcão Galeras durante a campanha<br>2006-2010 . . . . .                   | 27 |
| Figura 7  | Registro de evento sísmico TOR do vulcão Galeras durante a campanha<br>2006-2010 . . . . .                  | 28 |
| Figura 8  | Registro de evento sísmico HY do vulcão Galeras registrado na estação<br><i>Urcunina</i> . . . . .          | 29 |
| Figura 9  | Registro de tremores durante diferentes períodos eruptivos no vulcão<br><i>Popocatepetl</i> . . . . .       | 31 |
| Figura 10 | Efeitos de sitio nos sismogramas para um evento LP registrado nas es-<br>tações do Vulcão Galeras . . . . . | 33 |
| Figura 11 | Processo eruptivo em vulcões ativos . . . . .                                                               | 40 |
| Figura 12 | Estratégias básicas para a redução da dimensionalidades para represen-<br>tar dados . . . . .               | 54 |
| Figura 13 | Características geofísicas para dois eventos sísmicos (VT e LP) . . . . .                                   | 55 |
| Figura 14 | Histograma de distribuição das classes e duração dos eventos sísmicos . . . . .                             | 62 |
| Figura 15 | Filtragem dos sinais de eventos sísmicos . . . . .                                                          | 64 |
| Figura 16 | Esquema da arquitetura Autoencoder . . . . .                                                                | 70 |
| Figura 17 | Esquema da arquitetura Autoencoder Dual de Características (DAF) . . . . .                                  | 73 |
| Figura 18 | Respostas de ativação e derivada das funções <i>sigmoid</i> e <i>tanh</i> . . . . .                         | 74 |
| Figura 19 | Configuração experimental . . . . .                                                                         | 78 |
| Figura 20 | Coeficientes LPC dos sinais no domínio do tempo . . . . .                                                   | 82 |
| Figura 21 | Correlação por classe para a caracterização LPC . . . . .                                                   | 83 |
| Figura 22 | Análise de Discriminante Linear para a caracterização LPC . . . . .                                         | 83 |
| Figura 23 | Caracterização dos sinais usando a técnica LFCC . . . . .                                                   | 84 |
| Figura 24 | Correlação por classe para a caracterização LFCC . . . . .                                                  | 85 |
| Figura 25 | Análise de Discriminante Linear para a caracterização LFCC . . . . .                                        | 86 |

|           |                                                                                                  |     |
|-----------|--------------------------------------------------------------------------------------------------|-----|
| Figura 26 | Caracterização dos sinais usando a técnica PCA . . . . .                                         | 87  |
| Figura 27 | Correlação por classe para a caracterização PCA . . . . .                                        | 88  |
| Figura 28 | Análise de Discriminante Linear para a caracterização PCA . . . . .                              | 88  |
| Figura 29 | Caracterização dos sinais usando a técnica DAF . . . . .                                         | 89  |
| Figura 30 | Correlação por classe para a caracterização DAF . . . . .                                        | 90  |
| Figura 31 | Análise de Discriminante Linear para a caracterização DAF . . . . .                              | 91  |
| Figura 32 | Validação Cruzada Estratificada no modelo de classificação . . . . .                             | 92  |
| Figura 33 | Curva ROC para a validação interna de sinais aplicando LPC . . . . .                             | 93  |
| Figura 34 | Curva Precision-Recall para a validação interna de sinais aplicando LPC                          | 93  |
| Figura 35 | Curva ROC para a validação interna de sinais aplicando PCA . . . . .                             | 94  |
| Figura 36 | Curva Precision-Recall para a validação interna de sinais aplicando PCA                          | 94  |
| Figura 37 | Curva ROC para a validação interna de sinais aplicando DAF . . . . .                             | 95  |
| Figura 38 | Curva Precision-Recall para a validação interna de sinais aplicando DAF                          | 95  |
| Figura 39 | Matriz de confusão obtida após a classificação de sinais aplicando LPC                           | 96  |
| Figura 40 | Curva ROC na classificação de sinais aplicando LPC . . . . .                                     | 98  |
| Figura 41 | Curva Precision-Recall na classificação de sinais aplicando LPC . . . . .                        | 99  |
| Figura 42 | Matriz de confusão na classificação de sinais aplicando PCA . . . . .                            | 99  |
| Figura 43 | Curva ROC na classificação de sinais aplicando PCA . . . . .                                     | 101 |
| Figura 44 | Curva Precision-Recall na classificação de sinais aplicando PCA . . . . .                        | 102 |
| Figura 45 | Matriz de confusão na classificação de sinais aplicando DAF . . . . .                            | 102 |
| Figura 46 | Curva ROC na classificação de sinais aplicando DAF . . . . .                                     | 104 |
| Figura 47 | Curva Precision-Recall na classificação de sinais aplicando o DAF . . . . .                      | 105 |
| Figura 48 | Validação cruzada estratificada no modelo de classificação no domínio<br>da frequência . . . . . | 106 |
| Figura 49 | Curva ROC para a validação interna de sinais aplicando LFCC . . . . .                            | 107 |
| Figura 50 | Curva Precision-Recall para a validação interna de sinais aplicando LFCC                         | 108 |
| Figura 51 | Curva ROC para a validação interna de sinais aplicando PCA . . . . .                             | 108 |
| Figura 52 | Curva Precision-Recall para a validação interna de sinais aplicando PCA                          | 109 |
| Figura 53 | Curva ROC para a validação interna de sinais aplicando DAF . . . . .                             | 110 |
| Figura 54 | Curva Precision-Recall para a validação interna de sinais aplicando DAF                          | 110 |
| Figura 55 | Matriz de confusão na classificação de sinais aplicando LFCC . . . . .                           | 111 |
| Figura 56 | Curva ROC na classificação de sinais aplicando LFCC . . . . .                                    | 113 |
| Figura 57 | Curva Precision-Recall na classificação de sinais aplicando LFCC . . . . .                       | 114 |

## LISTA DE TABELAS

|           |                                                                          |     |
|-----------|--------------------------------------------------------------------------|-----|
| Tabela 1  | Estações que compreendem a rede sísmica no vulcão Galeras . . . . .      | 20  |
| Tabela 2  | Terminologia de sismologia vulcânica . . . . .                           | 25  |
| Tabela 3  | Fatores que influenciam os processos vulcânicos . . . . .                | 39  |
| Tabela 4  | Visão geral dos trabalhos relatados . . . . .                            | 48  |
| Tabela 5  | Características da natureza geofísica . . . . .                          | 56  |
| Tabela 6  | Seleção de hiperparâmetros ótimos para o DAF . . . . .                   | 76  |
| Tabela 7  | Resumo dos hiperparâmetros no classificador MLP . . . . .                | 77  |
| Tabela 8  | Interpretação dos valores AUC na curva ROC . . . . .                     | 80  |
| Tabela 9  | Relatório de métricas na classificação de sinais aplicando LPC . . . . . | 97  |
| Tabela 10 | Reporte de métricas na classificação de sinais aplicando PCA . . . . .   | 100 |
| Tabela 11 | Reporte de métricas na classificação de sinais aplicando DAF . . . . .   | 103 |
| Tabela 12 | Reporte de métricas na classificação de sinais aplicando LFCC . . . . .  | 112 |



## SUMÁRIO

|                |                                                          |           |
|----------------|----------------------------------------------------------|-----------|
| <b>1</b>       | <b>INTRODUÇÃO</b>                                        | <b>15</b> |
| <b>2</b>       | <b>SISMOLOGIA VULCÂNICA</b>                              | <b>19</b> |
| 2.1            | Sismologia no vulcão Galeras                             | 19        |
| 2.2            | Sismologia no vulcão Monte Etna                          | 21        |
| 2.3            | Sismologia do Vulcão Vulcano (Ilhas Eólias)              | 23        |
| 2.4            | Eventos sísmicos de atividade vulcânica                  | 23        |
| <b>2.4.1</b>   | <b>Efeitos de localização e propagação</b>               | <b>32</b> |
| <b>2.4.2</b>   | <b>Eventos externos ao vulcão</b>                        | <b>34</b> |
| 2.5            | Monitoramento de vulcões ativos                          | 35        |
| <b>2.5.1</b>   | <b>Registros sísmicos</b>                                | <b>35</b> |
| <b>2.5.2</b>   | <b>Monitoramento sísmico</b>                             | <b>36</b> |
| 2.6            | Processo eruptivo                                        | 37        |
| <b>3</b>       | <b>CLASSIFICAÇÃO DE SINAIS SISMO-VULCÂNICAS</b>          | <b>41</b> |
| 3.1            | Técnicas de classificação de sinais de sismos vulcânicos | 41        |
| <b>3.1.1</b>   | <b>Aprendizado baseado em instâncias</b>                 | <b>43</b> |
| <b>3.1.2</b>   | <b>Modelos discriminativos</b>                           | <b>43</b> |
| <i>3.1.2.1</i> | <i>Máquinas de Vetores Suporte</i>                       | <i>43</i> |
| <i>3.1.2.2</i> | <i>Redes Neurais Artificiais</i>                         | <i>44</i> |
| <b>3.1.3</b>   | <b>Modelos probabilísticos</b>                           | <b>44</b> |
| <i>3.1.3.1</i> | <i>Modelos de Misturas gaussianas</i>                    | <i>45</i> |
| <i>3.1.3.2</i> | <i>Modelos probabilísticos gráficos</i>                  | <i>45</i> |
| <i>3.1.3.3</i> | <i>Modelos ocultos de Markov</i>                         | <i>46</i> |
| <b>3.1.4</b>   | <b>Combinação de métodos ou ensembles</b>                | <b>46</b> |
| 3.2            | Técnicas de Caracterização                               | 53        |
| <b>3.2.1</b>   | <b>Seleção de características</b>                        | <b>53</b> |
| <i>3.2.1.1</i> | <i>Características de natureza geofísica</i>             | <i>54</i> |
| <i>3.2.1.2</i> | <i>Características de natureza estatística</i>           | <i>56</i> |
| <b>3.2.2</b>   | <b>Transformação de características</b>                  | <b>58</b> |

|                  |                                                                           |           |
|------------------|---------------------------------------------------------------------------|-----------|
| <b>4</b>         | <b>METODOLOGIA</b>                                                        | <b>61</b> |
| 4.1              | Banco de dados                                                            | 61        |
| <b>4.1.1</b>     | <b>Adequação dos dados</b>                                                | <b>62</b> |
| <i>4.1.1.1</i>   | <i>Duração dos eventos</i>                                                | <i>63</i> |
| <i>4.1.1.2</i>   | <i>Filtragem dos sinais</i>                                               | <i>63</i> |
| <i>4.1.1.3</i>   | <i>Normalização dos sinais</i>                                            | <i>64</i> |
| 4.2              | Caracterização dos sinais de sismos vulcânicos                            | 65        |
| <b>4.2.1</b>     | <b>Análises de Componentes Principais (PCA)</b>                           | <b>65</b> |
| <b>4.2.2</b>     | <b>Codificação de Predição Linear (LPC)</b>                               | <b>66</b> |
| <b>4.2.3</b>     | <b>Coeficientes Cepstrais de Frequencia Linear (LFCC)</b>                 | <b>68</b> |
| <b>4.2.4</b>     | <b>Autoencoder Dual de Características (DAF)</b>                          | <b>69</b> |
| <i>4.2.4.1</i>   | <i>Arquitetura Autoencoder</i>                                            | <i>69</i> |
| <i>4.2.4.2</i>   | <i>Autoencoder Dual de Características como técnica de caracterização</i> | <i>72</i> |
| 4.3              | Modelo de classificação                                                   | 76        |
| 4.4              | Configuração Experimental                                                 | 77        |
| 4.5              | Métricas de Avaliação                                                     | 78        |
| <b>5</b>         | <b>RESULTADOS</b>                                                         | <b>81</b> |
| 5.1              | Resultados da caracterização                                              | 81        |
| <b>5.1.1</b>     | <b>Caracterização dos sinais usando a técnica LPC</b>                     | <b>81</b> |
| <b>5.1.2</b>     | <b>Caracterização dos sinais usando a técnica LFCC</b>                    | <b>84</b> |
| <b>5.1.3</b>     | <b>Caracterização dos sinais usando a técnica PCA</b>                     | <b>86</b> |
| <b>5.1.4</b>     | <b>Caracterização dos sinais usando a técnica DAF</b>                     | <b>89</b> |
| 5.2              | Resultados de Classificação                                               | 91        |
| <b>5.2.1</b>     | <b>Classificação dos dados no domínio do tempo</b>                        | <b>91</b> |
| <i>5.2.1.1</i>   | <i>Validação Cruzada Estratificada</i>                                    | <i>91</i> |
| <i>5.2.1.1.1</i> | <i>Validação interna para dados caracterizados com LPC</i>                | <i>92</i> |
| <i>5.2.1.1.2</i> | <i>Validação interna para dados caracterizados com PCA</i>                | <i>93</i> |
| <i>5.2.1.1.3</i> | <i>Validação interna para dados caracterizados com o DAF</i>              | <i>94</i> |
| <i>5.2.1.2</i>   | <i>Validação externa</i>                                                  | <i>96</i> |
| <i>5.2.1.2.1</i> | <i>Validação externa para dados caracterizados com LPC</i>                | <i>96</i> |
| <i>5.2.1.2.2</i> | <i>Validação externa para dados caracterizados com PCA</i>                | <i>99</i> |

|           |                                                                         |     |
|-----------|-------------------------------------------------------------------------|-----|
| 5.2.1.2.3 | <i>Validação externa para dados caracterizados com o DAF</i>            | 102 |
| 5.2.2     | <b>Classificação dos dados no domínio da frequência</b>                 | 105 |
| 5.2.2.1   | <i>Validação Cruzada Estratificada</i>                                  | 105 |
| 5.2.2.2   | <i>Validação interna (Domínio da frequência)</i>                        | 107 |
| 5.2.2.2.1 | <i>Validação interna para dados caracterizados com LFCC</i>             | 107 |
| 5.2.2.2.2 | <i>Validação interna com caracterização PCA (Domínio da frequência)</i> | 108 |
| 5.2.2.2.3 | <i>Validação interna com caracterização DAF (Domínio da frequência)</i> | 109 |
| 5.2.2.3   | <i>Validação externa</i>                                                | 111 |
| 5.2.2.3.1 | <i>Validação externa para dados caracterizados com LFCC</i>             | 111 |
| 6         | <b>CONCLUSÕES</b>                                                       | 115 |
| 6.1       | Sugestões para trabalhos futuros                                        | 116 |
|           | <b>REFERÊNCIAS</b>                                                      | 117 |

## 1 INTRODUÇÃO

A atividade vulcânica sempre despertou a atenção da comunidade científica, sendo considerada uma janela aberta para compreender os processos internos da Terra (McGuire; Kilburn; Murray, 2022). O monitoramento vulcânico, definido por Banks et al. (1989) como "a compilação dos estudos científicos de dados sistematicamente observados, registrados e analisados de fenômenos visíveis e invisíveis em um vulcão e seus arredores", constitui uma manifestação superficial da dinâmica interna da Terra.

A vigilância da atividade vulcânica é complexa, pois exige inferir, a partir do exterior, o que está acontecendo no interior de um vulcão. Esse monitoramento requer uma variedade de instrumentos e técnicas para estudar e interpretar as dinâmicas dos fluidos magmáticos e hidrotermais antes e durante uma agitação vulcânica (Aki, 1992). Graças à diversidade crescente das técnicas geofísicas, geoquímicas e geodésicas, a vigilância e a previsão de erupções se tornaram possíveis, com a sismologia desempenhando um papel fundamental nos programas de monitoramento vulcânico (Saccorotti; Lokmer, 2021)).

A análise da sismicidade vulcânica pode ser mais complexa do que a dos terremotos tectônicos usuais, envolvendo dinâmicas não lineares dos fluidos internos e da estrutura que geram os sinais sísmicos, além de processos acoplados de radiação sísmica (Scarpa et al., 1996; Lahr et al., 1994). Portanto, a modelagem de um sistema vulcânico para compreender o comportamento e a evolução de uma agitação vulcânica é detalhada, exigindo análise de dados registrados em diversas escalas de tempo (McGuire; Kilburn; Murray, 2022).

A sismologia vulcânica permite inferir as mudanças dos sistemas magmáticos ativos e determinar suas propriedades físicas, fornecendo uma compreensão mais detalhada da extensão e evolução das regiões e fontes de energia. Isso ajuda a avaliação dos riscos vulcânicos e na compreensão do comportamento eruptivo (Scarpa; Tilling; Chouet, 1996). Logo, a vigilância da atividade sísmica é essencial para determinar e avaliar os riscos associados.

A presença de vulcões em regiões povoadas representa um desafio para as autoridades públicas, visando evitar desastres e perdas fatais, como a tragédia em Armero (Colômbia), causada pela erupção do vulcão Nevado del Ruiz, resultando em 23.000 vítimas fatais (Voight, 1990). Desde então, as Nações Unidas, em colaboração com a União Europeia, iniciaram programas de pesquisa integrando equipes de cientistas e cooperação internacional para estabelecer programas de vigilância vulcânica e prevenir catástrofes de grande magnitude (Chester; Dikken; Duncan, 2002; Tilling, 2008).

Assim, a metodologia da vigilância da atividade vulcânica têm evoluído, desenvolvendo pesquisas direcionadas a três objetivos principais: compreender o passado por meio de estudos geológicos e dados registrados, compreender o presente por meio de monitoramento, e prever o futuro utilizando interpretações do passado e do presente (Dondin et al., 2019).

Além do avanço na pesquisa do monitoramento da atividade sísmica vulcânica, houve um progresso significativo na tecnologia da instrumentação dos sistemas de monitoramento, resultando em um aumento considerável na quantidade de dados disponíveis para análise. Contudo, uma grande base de dados permanece subutilizada devido ao alto custo associado à sua rotulagem manual e computacional (Malfante et al., 2018; Bueno et al., 2020). Assim, as análises sísmicas frequentemente se concentram em subconjuntos relativamente pequenos de sismos vulcânicos (Bueno et al., 2020).

Assim como em muitos casos de *big data*, as técnicas de aprendizado automático tornaram-se essenciais para automatizar a análise de anos de sinais de sismos vulcânicos registrados. Consequentemente, o aprendizado automático emerge como uma ferramenta atrativa para a sísmologia (Malfante et al., 2018). Suas vantagens incluem a capacidade de realizar mapeamento não linear, a modelagem de dados sequenciais, a extração e transformação automática de recursos, redução de dimensionalidade e parametrização, tornando-se uma ferramenta robusta e confiável na classificação de sinais de sismos vulcânicos.

As redes neurais artificiais (*Artificial Neural Network* - ANN) (Ibarra, 2011; Pezzo et al., 2003; Scarpetta et al., 2005; Esposito et al., 2013a; Geng; Wang, 2020; Bueno et al., 2020; Malfante et al., 2018) e os modelos ocultos de Markov (*Hidden Markov Model* - HMM) (Benítez et al., 2006; Ibáñez et al., 2009a; Bicego; Acosta-Munoz; Orozco-Alzate, 2012; Moreno, 2015) estão entre os algoritmos mais utilizados na classificação de sinais de sismos vulcânicos. Contudo, o desempenho desses modelos de classificação apresenta vários desafios, destacando-se a necessidade de um conjunto de dados rotulados de tamanho adequado para realizar o treinamento e validação do modelo. Outro problema é a distribuição desbalanceada das classes, onde uma delas contém um número dominante de instâncias ou exemplos.

A natureza dos sinais sísmicos depende da agitação vulcânica presente. Isso exige que os modelos de classificação sejam o suficientemente robustos para lidar com o desbalanceamento de classes no conjunto de dados, evitando a tendência do modelo de aprender apenas a classe majoritária ou dominante, prejudicando a previsão das demais classes (Moreno, 2015; Bi; Zhang, 2018; Wasikowski; Chen, 2009). Esse desafio torna-se mais acentuado quando o conjunto de dados não possui um número suficiente de instâncias da classe minoritária.

Na literatura, é comum optar por equilibrar as classes, descartando aleatoriamente dados da classe majoritária, até alcançar uma distribuição relativamente equilibrada. Contudo, essa

estratégia implica na redução do tamanho do conjunto de dados. Por isso, muitos estudos de classificação de sismos vulcânicos não utilizam conjuntos de dados com mais de 500 registros (Malfante et al., 2018; Ibarra, 2011; Titos et al., 2018b; Brusil et al., 2019; Cortés et al., 2015). Tal abordagem acarreta em perda de informação nos dados (Wasikowski; Chen, 2009; Ali et al., 2019; García; Sánchez; Mollineda, 2012; Ng et al., 2016). Além do método de balanceamento das classes, há uma alternativa baseada na seleção e transformação de características (Wasikowski; Chen, 2009), também conhecida como caracterização ou representação (Ng et al., 2016; Cortés et al., 2014). Dessa forma, é possível apresentar ao modelo de classificação um conjunto de dados desbalanceado sem afetar seu desempenho.

Outro desafio importante nos dados de registros sísmicos de origem vulcânica é a alta dimensionalidade, o que pode tornar o modelo de classificação computacionalmente dispendioso. Por essa razão, a seleção de características desempenha um papel fundamental na eficácia dos algoritmos de classificação automática, permitindo uma redução significativa da dimensionalidade dos dados. Moreno (2015) menciona que a quantidade de dados necessária para obter resultados estatisticamente significativos cresce exponencialmente com a dimensionalidade dos dados. Assim, a capacidade de generalização do modelo de classificação melhora quando há um menor quociente entre o número de instâncias e a dimensão do espaço de características. Essa relação também é mencionada por Bishop et al. (1995), Corporation e Bellman (1961), Kubat (2005).

Este trabalho de pesquisa propõe um Autoencoder Dual de Características (DAF), como uma técnica inovadora capaz de obter uma representação de menor dimensão dos sinais de sismos vulcânicos e lidar simultaneamente com o problema de conjuntos de dados desbalanceados. O modelo de aprendizado de representação proposto baseia-se em dois Autoencoders empilhados que utilizam diferentes funções de ativação. A função de ativação *sigmoid* é menos sensível às mudanças, proporcionando uma representação mais robusta; enquanto a função de ativação *tanh* é mais sensível, oferecendo informações mais detalhadas sobre os dados (Ng et al., 2016). Dessa forma, é possível obter uma representação eficiente com as características mais representativas dos sinais sísmicos.

Assim, as principais contribuições deste trabalho incluem a abordagem do problema de desbalanceamento das classes no conjunto de sinais de sismos vulcânicos, especialmente quando o conjunto de dados rotulados é insuficiente em tamanho. Além disso, oferece uma nova técnica de caracterização robusta e eficiente, com a capacidade de definir as classes de sismos vulcânicos, facilitando assim o processo de classificação. A técnica proposta é comparada com as abordagens convencionais de caracterização encontradas na literatura, como o uso de coeficientes de predição linear (LPC)(Makhoul, 1975), o uso de coeficientes cepstrais de frequência

linear (LFCC) e a análise de componentes principais (PCA)(Hotelling, 1933).

Este texto está dividido em sete capítulos. O segundo capítulo está dedicado à sismologia vulcânica mostrando as classes de sismos vulcânicos, os efeitos de sítio e propagação que podem afetar os sinais, e os contextos vulcânicos de Galeras, Etna e vulcão Vulcano. No terceiro capítulo se descreve brevemente o estado da arte na classificação dos sinais de sismos vulcânicos e as técnicas de caracterização usadas como parte do processamento dos sinais. O quarto capítulo mostra a metodologia empregada nesta pesquisa, descrevendo os dados utilizados, as técnicas de caracterização, entre as quais se descreve a técnica de caracterização proposta, usando Autoencoders. Também se descreve o modelo de classificação e as métricas de avaliação. O quinto capítulo mostra e discute os resultados do pré-processamento, e o desempenho de classificação quando os sinais estão no domínio do tempo e da frequência. O modelo foi testado com dados de Galeras, mas também com os dados externos dos vulcões Etna e Vulcano. Finalmente o texto apresenta os capítulos de conclusões deste trabalho de pesquisa e propõe os trabalhos futuros que podem ser desenvolvidos seguindo esta linha de atuação.


## 2 SISMOLOGIA VULCÂNICA

A sismologia vulcânica busca compreender a localização e a evolução da dinâmica dos processos físicos relacionados com o magma ativo, aos fluidos termais e à estrutura rochosa, por meio dos sinais sísmicos gerados. Esta informação é fundamental na geofísica para compreender a estrutura interna da Terra, analisar a atividade vulcânica e avaliar os riscos associados aos vulcões (Scarpa; Tilling, 2012).

### 2.1 Sismologia no vulcão Galeras

O vulcão Galeras está localizado na Colômbia no departamento de Nariño, aproximadamente a 9 km ao oeste da cidade de San Juan de Pasto, capital do departamento. As coordenadas geográficas são 1°13'43.8"latitude norte e 77°21'33.0"longitude oeste, com uma altitude de 4276 metros sobre o nível do mar. A Figura 1 indica o mapa de localização do vulcão elaborado pelo Serviço Geológico Colombiano. Aproximadamente uma população de 500.000 pessoas mora na área de influência do vulcão Galeras.

Figura 1 - Localização vulcão Galeras



Fonte: *Generalidades volcán Galeras* (Servicio Geológico Colombiano, ).

De acordo com os registros do Observatório vulcanológico e sismológico de Pasto (OVSP), foram contabilizadas 21 erupções explosivas do tipo vulcânico desde o início do monitoramento



permanente em 1989. A maioria das erupções têm sido catalogadas como vulcanianas, com colunas de baixa altura (abaixo de 10 km), com emissões de gases e cinzas, e erupções explosivas com geração de fluxos piroclásticos que alcançaram distancias de até 9.5 km a partir da cratera (Servicio Geológico Colombiano, ). O vulcão Galeras é um dos vulcões andesíticos mais ativos da Colômbia; suas erupções históricas são caracterizadas pela formação de cúpulas efusivas e erupções vulcânicas explosivas (Williams; Calvache, 1997).


A rede de monitoramento sísmico é composta por 16 estações, conforme descrito na Tabela 1 e ilustrado na Figura 2, que mostra a localização das estações. Durante o monitoramento sismológico foram registrados diferentes tipos de terremotos, incluindo terremotos vulcão-tectônicos (VT), sismos de longo período (LP), sismos tipo *Tornillo* (TOR) e tremores (TRE), os quais serão explicados com mais detalhes posteriormente neste capítulo.

Tabela 1 - Estações que compreendem a rede sísmica no vulcão Galeras

| <b>Estação</b> | <b>Abreviatura</b> | <b>Tipo sensor</b> | <b>Distância cratera (km)</b> | <b>Altitude (msnm)</b> |
|----------------|--------------------|--------------------|-------------------------------|------------------------|
| Achalay        | ACHV               | Banda larga        | 0.6                           | 4134                   |
| Anganoy        | CONO               | Banda larga        | 0.7                           | 4277                   |
| Arlés          | ARLS               | Banda larga        | 4                             | 3450                   |
| Calabozo       | CAL1               | Banda larga        | 6.9                           | 2313                   |
| Cobanegra      | CBA1               | Banda larga        | 4.3                           | 3625                   |
| Cóndor         | COND               | Banda larga        | 4.4                           | 3977                   |
| Cráter         | CRAD               | Banda larga        | 1.5                           | 4032                   |
| Cufiño         | CRVZ               | Banda larga        | 1.4                           | 3828                   |
| Ingenio        | CAVZ               | Banda larga        | 7                             | 2890                   |
| Loma larga     | CHPL               | Curto período      | 14.2                          | 2313                   |
| Morasurco      | MINV               | Curto período      | 13.7                          | 3504                   |
| Nariño         | NAR1               | Banda larga        | 5.29                          | 2856                   |
| Obonuco        | OBUZ               | Banda larga        | 5.4                           | 3021                   |
| San Felipe     | PLAZ               | Banda larga        | 7.6                           | 3491                   |
| Tosoabí        | PUY1               | Banda larga        | 10.6                          | 2898                   |
| Urcunina       | URCR               | Banda larga        | 11.4                          | 2622                   |

Fonte: Rede de monitoramento sísmico Galeras, OVSP (Servicio Geológico Colombiano, ).

Figura 2 - Rede monitoramento sísmico Galeras




Fonte: Rede sísmica Galeras (Londoño; Kumagai; Torres, 2020).

## 2.2 Sismologia no vulcão Monte Etna

O Monte Etna é o vulcão mais ativo na Europa continental, com uma história eruptiva muito longa. Está localizado ao sul da Itália no leste da Sicília como se indica na Figura 3. As coordenadas geográficas são  $37^{\circ} 44' 52.8''$ N latitude norte e  $14^{\circ} 59' 56.4''$  longitude este, com uma altitude de 3324 metros sobre o nível do mar, com uma extensão aproximada de  $1250 \text{ km}^2$  (Osservatorio Etneo, Sezione de Catania, ).

Trata-se de um estratovulcão com tipos de erupções efusivas e estrombolianas, que se caracterizam pela liberação de lava devido à acumulação de gases. Apresentando fenômenos dominantes, como a desgaseificação das crateras do cume, além de erupções lávicas tão potentes que podem atingir alturas de vários quilômetros devido ao magma em ascensão através do conduto central aberto (Mattia et al., 2020). Também são registradas erupções laterais provenientes de aberturas eruptivas. Além disso, são observadas deformações do solo e uma considerável atividade sísmica (Venzke; Bennis, 2022).


Figura 3 - Localização de vulcões na Itália



Fonte: Mapa consultado no (INGV, 2023).

O monitoramento sísmico do Monte Etna é conduzido pelo Observatório Etneo do Instituto Nacional de Geofísica e Vulcanologia (INGV-OE), que atualmente opera com 14 estações com sismômetros digitais. Dessas estações, 5 estão localizadas diretamente no Monte Etna, 3 estão distribuídas no arquipélago Eólio, enquanto as 6 estações restantes estão posicionadas na área da Sicília Oriental, no sul da Calábria e no planalto de *Hyblaean*, conforme ilustrado na Figura 4. Os Sinais sísmicos registrados no Monte Etna correspondem sinais do tipo VT, LP e TRE, considerados representativos dos processos dinâmicos durante as fases de recarga e os períodos eruptivos (Venzke; Bennis, 2022). Estes sinais refletem as relações entre as tensões regionais e locais induzidas pelos movimentos do magma na crosta (Mattia et al., 2020).

Figura 4 - Rede de monitoramento sísmico do INGV-OE



Fonte: Mapa consultado no (Osservatorio Etneo, Sezione de Catania, ).

### 2.3 Sismologia do Vulcão Vulcano (Ilhas Eólias)

O Vulcão do arquipélago das ilhas Eólias no Sul do Mar Tirreno está localizado a 38° 24' 14.4" de latitude Norte e 14° 57' 43.2" com longitude Este como indica a Figura 3, com uma extensão aproximada de 21 km<sup>2</sup> (Osservatorio Etneo, Sezione de Catania, ).

O Vulcão (Ilhas Eólias) é um estratovulcão que apresenta erupções estrombolianas e explosivas, acompanhadas por fenômenos como emissões fumarólicas e emissões hidrotermais apesar da baixa sismicidade. Erupções anteriores resultaram no colapso do edifício vulcânico em três ocasiões distintas. Desde a última erupção, o vulcão está em estado de intensa desgaseificação (Cannata et al., 2012).

O monitoramento está a cargo do INGV-OE com uma estação alocada no cume do vulcão como ilustra a Figura 4. Na crise mais recente, os sistemas de monitorização identificaram sinais de sismos do tipo VT, LP, tipo *Tornillo*, alta frequência e eventos monocromáticos, e também deformações do edifício vulcânico (Alparone et al., 2010; Cannata et al., 2012).

### 2.4 Eventos sísmicos de atividade vulcânica

O uso de observações sismológicas no monitoramento e na previsão de erupções vulcânicas é justificado, uma vez que quase todas as erupções vulcânicas monitoradas sísmicamente foram acompanhadas por algum tipo de anomalia sísmica. Os trabalhos pioneiros de Omori (1912), Sassa (1936), Imbò (1954), dedicaram-se ao estudo dos sinais sísmicos que precedem e acompanham as erupções vulcânicas, estabelecendo assim as bases da sismologia.

Posteriormente, com a introdução dos primeiros instrumentos portáteis equipados com sensores sísmicos, surgiram pesquisas e teorias que buscaram entender a relação entre a atividade sísmica e os processos geofísicos envolvidos. Os sismólogos começaram a se interessar nos sinais anômalos que apresentaram amplitudes elevadas ou um comportamento inusitado no conteúdo espectral. As técnicas desenvolvidas por Aki et al. (1978), Helz (1993) serviram como ponto de partida para associação da atividade sísmica à estrutura interna do vulcão, resultando em um modelo analítico da dinâmica do magma.

Logo após o início de um monitoramento sísmico mais extenso, ficou evidente que os vulcões apresentam uma variedade de sinais sísmicos distintos (Lahr et al., 1994). No entanto, o significado físico dos diferentes eventos sísmicos e sua relação com a elevação do magma ainda não são bem compreendidos. É necessário distinguir entre atividades internas vulcânicas que podem resultar em uma intrusão magmática ou em uma erupção em desenvolvimento, ambas gerando um grande número de sinais sísmicos (Scandone; Cashman; Malone, 2007).

Com relação à variedade dos vulcões, dos estilos eruptivos, das diferentes composições magmáticas e mudanças de viscosidade, é interessante observar que existem tipos comuns de

sinais sísmicos que podem ser classificados em categorias. Essa classificação é importante porque cada tipo de sinal pode representar um mecanismo físico de fonte diferente (Chouet, 2003). No entanto, a classificação pode ser um processo complexo, onde é necessário observar e analisar cuidadosamente os padrões espaciais e temporais nos diferentes tipos de sinais, os quais podem revelar uma compressão mais profunda das dinâmicas internas do vulcão.

Embora não exista atualmente um esquema global uniforme de classificação, é possível encontrar características comuns que permitem comparar os sinais de terremotos e associá-los a diferentes fontes sismo-vulcânicas (Ibáñez et al., 2000). Assim, os sinais sísmicos são frequentemente agrupados em famílias de eventos, o que auxilia na avaliação das possíveis fontes sísmicas e sua relação com o processo vulcânico em curso (Chouet; Matoza, 2013), sendo fundamental para uma interpretação adequada dos fenômenos vulcânicos.

Os registros dos eventos sísmicos podem ser classificados a partir de duas perspectivas. A primeira é a representação no domínio do tempo no sismograma, que apresenta a desvantagem da grande variabilidade que um mesmo tipo de evento sísmico pode ter devido aos efeitos de sítio. A segunda perspectiva é a identificação dos mecanismos da fonte que geram os sinais sísmicos, o que requer informações mais detalhadas sobre a localização, magnitude, velocidade, entre outros, nem sempre disponíveis. Por tanto, o critério mais aceito é diferenciar os eventos com base em sua forma de onda e nas propriedades espectrais de concentração de energia, envelope e evolução temporal a partir do sismograma (Chouet, 2003). No entanto, deve-se levar em consideração que, tanto no domínio do tempo como da frequência, existem características que são resultado da fonte geradora, dos efeitos locais e dos efeitos de propagação no meio.

Existem terminologias locais diferentes para identificar os tipos de terremotos vulcânicos. A Tabela 2 tenta mapear várias das terminologias mais comuns, levando em conta as características que podem associar eventos em grupos que compartilham a mesma forma de onda, informação espectral ou que podem ajudar a avaliar potenciais fontes sísmicas.

Como pode ser visto na Tabela 2, embora a maioria das terminologias de classificação de sinais sísmicos seja descritiva nas características do sismograma, este trabalho usará a terminologia de classificação com base no processo de ordem física que enfatiza o processo de origem (Latter, 1979), como é a classe Vulcano Tectônico (VT), Largo Período (LP) e tipo *Tornillo* (TOR), embora alguns autores o considerem como parte dos sismos LP, neste trabalho consideraremos este tipo como uma classe aparte.

- **Terremotos vulcano-tectônicos (VT).** São sismos tectônicos que ocorrem dentro da região de um vulcão, como resultado das tensões no edifício vulcânico provocado pela elevação do magma ou pelo relaxamento produzido após uma erupção. A injeção de fluidos, causa acumulação de energia e variações de pressão, ativando falhas locais e gerando

Tabela 2 - Terminologia de sismologia vulcânica

| (Scarpa; Tilling, 2012) | (Minakami, 1974)      | (Latter, 1979)     | (Lahr et al., 1994; Scarpa; Tilling; Chouet, 1996) | <b>Outros nomes</b>                |
|-------------------------|-----------------------|--------------------|----------------------------------------------------|------------------------------------|
| Alta frequência (HF)    | Tipo A                | Vulcano tectônico  | Vulcano-tectônico (VT)                             | Curto período                      |
| Baixa frequência (LF)   | Tipo B                | Vulcano tectônico  | Período longo (LP)                                 | Cauda longa, <i>Tor-nillo</i>      |
| Frequência variável     | -                     | Frequência média   | Híbridos                                           | Frequência média                   |
| Terremoto de explosão   | Terremoto de explosão | Explosão vulcânica | Explosão                                           | -                                  |
| Tremor vulcânico        | Tremor vulcânico      | Tremor vulcânico   | Tremor vulcânico                                   | Harmônico, Espasmódico e Impulsivo |

Fonte: Terminologia sismo-vulcânica, (Scarpa; Tilling, 2012).


fraturas e deformações no meio rochoso. As ondas P (*primae*) e S (*segrundae*) no sismograma destes eventos são bastante claras. Geralmente, estes sismos têm curta duração, com um início caracterizado por altas frequências, seguido de uma cauda que cai exponencialmente em relação ao tempo. A Figura 5 indica o registro de um evento VT no vulcão Galeras, no qual é possível identificar suas características no domínio do tempo e da frequência.

Estes sismos costumam ocorrer em enxames, com curtos intervalos de tempo entre eventos. Ao contrário dos terremotos exclusivamente tectônicos, os eventos VT muitas vezes se apresentam como eventos de tamanho semelhante, ao invés de uma sequencia após um choque principal e várias réplicas. Os sismos VT dividem-se em 2 tipos:


- VT profundos (VT-A): localizam-se a uma profundidade superior a 2 km. Possuem um alto conteúdo espectral acima de 10 Hz, o que também os torna conhecidos como eventos de alta frequência. A chegada das ondas P e S apresenta alta impulsividade e um alto conteúdo de frequências que se dispersa rapidamente ao atingir a superfície.
- VT superficiais (VT-B): localizam-se entre [1, 2] km de profundidade. Apresentam uma chegada emergente pouco impulsiva, onde a onda P pode ser detetada, mas nem sempre a onda S. A energia espectral concentra-se na banda de frequências entre [1,

10] Hz. O conteúdo de altas frequências dispersa-se rapidamente, porém, a energia demora para desaparecer, resultando em caldas mais prolongadas.


Figura 5 - Registro de evento sísmico VT do vulcão Galeras durante o período 2006-2010



(a) Sismograma, sinal no domínio do tempo.



(b) Espectro, sinal no domínio da frequência.



(c) Espectrograma, indicando o sinal em ambos domínios.


Fonte: Elaborado pelo autor.

- **Sismos de longo período (LP).** Também conhecidos como de baixa frequência. Nos registros sísmicos, não é possível identificar a chegada das ondas S, pois o início do sinal é muito emergente, a Figura 6 indica o registro de um sismo LP no vulcão Galeras.


São sinais muito superficiais, com profundidades inferiores a 2 km. A duração pode ser semelhante ao dos terremotos VTs, porém com conteúdo espectral em baixas frequências no intervalo entre [1, 10] Hz. Os sismos LP variam de um vulcão para outro, tanto no domínio do tempo como da frequência, pois dependem das características internas físicas e químicas de cada vulcão. Os enxames de sismos LP costumam estar associados a erupções e instruções magmáticas, sendo o mecanismo da fonte associado a cavidades que

ressonam quando o magma está ascendendo em direção à superfície, gerando oscilações (Chouet, 1996) e à mistura pouco viscosa de fluidos e gases no magma (Seidl; Schick; Riuscetti, 1981).


Figura 6 - Registro de evento sísmico LP do vulcão Galeras durante a campanha 2006-2010



(a) Sismograma, sinal no domínio do tempo.



(b) Espectro, sinal no domínio da frequência.



(c) Espectrograma, indicando o sinal em ambos domínios.


Fonte: Elaborado pelo autor.

- **Sismos *Tornillo* (TOR).** Recebem esse nome devido à forma característica de "parafuso" apresentada no sismograma desse sinal. Referem-se a eventos sísmicos de longo período associados a um mecanismo de fonte com ressonância, no qual a composição e das propriedades físicas dos fluidos envolvidos determinam os harmônicos dominantes e a duração do evento (GÓmez et al., 1999). Assim, eles parecem se originar de um processo de fonte comum aos sismos LP, porém com condições de excitação ou atenuação ligeiramente diferentes. Às vezes, observa-se que os sismos TOR e LPs contêm uma energia de alta frequência perto do início da forma de onda, com diferenças nas oscilações de baixa frequência nos sismos TOR. (Hagerty; Benites, 2003). A Figura 7 indica um




registro de sinal sísmica TOR captado no vulcão Galeras. No espectrograma, observa-se um início impulsivo da onda com uma cauda bastante longa, mostrando um decaimento lento da amplitude ao longo do tempo. O espectro indica poucos picos de frequência que contribuem para a energia do sismo, porém bem diferenciados.


Figura 7 - Registro de evento sísmico TOR do vulcão Galeras durante a campanha 2006-2010



(a) Sismograma, sinal no domínio do tempo.



(b) Espectro, sinal no domínio da frequência.




(c) Espectrograma, indicando o sinal em ambos domínios.

Fonte: Elaborado pelo autor.


- **Eventos híbridos (HY).** Também conhecidos como eventos multi-fase (**MP**). Englobam propriedades de eventos VTs (permitindo identificar a chegada de onda P) seguido de um sinal de baixa frequência, apresentando uma chegada impulsiva de alta energia distribuída em uma ampla gama de frequências no intervalo entre [1, 25] Hz, com uma calda pouco dispersa em torno da frequência dominante, como pode ser observado na Figura 8, a qual indica um sismo híbrido registrado no vulcão Galeras. É possível observar a semelhança dos eventos mistos com a forma de onda VT-B, ao mesmo tempo em que compartilham

o modelo de fonte dos sismos LPs (Wassermann, 2012). Os mecanismos de origem estão associados a ambos tipos de eventos, onde um terremoto VT desencadeia um sismo LP próximo, podendo refletir atividades superficiais associadas ao domo em crescimento formado por lava viscosa, o que geralmente gera enxames superficiais (White et al., 1998).


Figura 8 - Registro de evento sísmico HY do vulcão Galeras registrado na estação *Urcunina*



(a) Sismograma, sinal no domínio do tempo.



(b) Espectro, sinal no domínio da frequência.




(c) Espectrograma, indicando o sinal em ambos domínios.

Fonte: Detalhes da componente NS na estação *Urcunina* para um sismo Híbrido (Ibarra, 2011).


- **Ruído ou tremor vulcânico (TRE).** São sinais de frequência muito baixa, entre [0.5, 10] Hz, com uma duração muito variada, desde minutos até dias ou semanas. Estes sismos exibem sismogramas quase estacionários ao longo do tempo, o que lhes confere o nome de ruído vulcânico. A origem desses sinais ainda não possui uma teoria definida com respeito à fonte que origina estes sinais. É possível que sejam gerados devido às mudanças de pressão e temperatura nos sistemas hidrotermais, frequentemente relacionado à presença de plumas de cinzas pesadas ou com vapor branco. Alguns autores observaram esses sinais em diferentes vulcões com magmas de baixa viscosidade, quando a interação gás-fluido entra em ressonância com harmônicos altamente estáveis. No entanto, existem autores na literatura que consideram esses sinais como parte dos eventos LPs, assumindo o mesmo modelo de mecanismos de fonte, porém, sujeitos à sobreposição de eventos mais simples. Podem ser distinguidos três tipos de tremores, conforme descritos por (Arámbula-Mendoza et al., 2016), como podem ser observados na Figura 9, juntamente com uma sequência de pulsos de baixa frequência.

- Tremor harmônico ressonante (TR): têm as maiores amplitudes com longas durações. Apresentam um ou vários harmônicos espaçados de forma regular como um trem de ondas geradas por varias frequências dominantes no intervalo de [0.1, 5] Hz. Acredita-se que sua origem esteja associada a sistemas hidrotermais sujeitos a variações de pressão e temperatura(Arámbula-Mendoza et al., 2016). Também se considera que os TR são o resultado da sobreposição de eventos LPs (Wassermann, 2012).
- Tremor espasmódico (TS): são menos regulares e mais caóticos do que os TR, apresentando uma energia espectral dispersa na banda de frequências entre [1, 10] Hz, com a presença de uma frequência dominante. Este tipo de tremores estão associados às sequencias de sismos VTs e às emissões de cinzas e gases de menor energia, observado durante pequenas erupções(Arámbula-Mendoza et al., 2016).
- Tremor pulsante (TP): caracterizado por apresentar pulsos sequenciais. É considerado como um evento misto, formado por um TS sobreposto por grupos de ondas(Arámbula-Mendoza et al., 2016). Geralmente, estes pulsos estão espaçados a cada 10 segundos, e seu espectro parece estar centrado em frequências entre[0.1, 5] Hz (Arámbula-Mendoza et al., 2011).


É importante mencionar que nem todos os autores concordam com a subclassificação dos tremores e suas respectivas fontes associadas. Alguns autores como Neuberg et al. (2000) incluem os sinais tremores no grupo dos LPs, considerando-os como um enxame de vários eventos deste tipo, onde a separação temporal vai diminuindo até se tornar um tremor pulsante e, posteriormente, um tremor espasmódico.

Figura 9 - Registro de tremores durante diferentes períodos eruptivos no vulcão *Popocatepetl*

(a) Tremor harmônico ressonante (TS)



(b) Tremor espasmódico (TS)



(c) Tremor Pulsante (TP)


Fonte: Episódios de tremor vulcânico no vulcão *Popocatepetl* em 2012-2014 (Arámbula-Mendoza et al., 2016).

### 2.4.1 Efeitos de localização e propagação


As ondas sísmicas contêm informações não apenas sobre a dinâmica vulcânica, mas também sobre a complexa estrutura interna do edifício vulcânico que afeta o campo de ondas sísmicas e sua interpretação. Na maioria dos vulcões, a topografia pronunciada e acidentada introduz efeitos complexos e severos, tais como interferência, atenuação ou mudanças no caminho seguido pelas ondas sísmicas diretas (Yeguas et al., 2011).

Quando é observado um registro sísmico no domínio do tempo a partir do sismograma, a forma de onda pode variar devido ao deslocamento do sensor, de modo que um mesmo evento pode parecer totalmente diferente quando é registrado por outra estação (Houghton et al., 2015). Os efeitos de propagação e de sitio também se combinam com os efeitos de dispersão, radiação, reflexão e refração das ondas sísmicas de origem tectônico, resultando em uma distorção do sinal, afetando, principalmente, as bandas de frequência média e alta [5, 25] Hz. Todos esses efeitos podem ser classificados de acordo com os efeitos do caminho (atenuação) e os efeitos da fonte (padrão de energia e radiação). A Figura 10 indica o registro de um mesmo sinal sísmico em diferentes estações, onde é possível identificar como os efeitos locais e de propagação podem afetar a forma de onda no sismograma.


Figura 10 - Efeitos de sitio nos sismogramas para um evento LP registrado nas estações do Vulcão Galeras




(a) Estação *Anganoy*.




(b) Estação *Cráter*.




(c) Estação *Cufiño*.



(d) Estação *Urcunina*.



(e) Estação *Cóndor*.



(f) Estação *Nariño*.

Fonte: Sismo LP registrado por várias estações no vulcão Galeras, (Ibarra, 2011).

### 2.4.2 Eventos externos ao vulcão

Estes eventos compreendem sinais relacionados à atividade vulcânica externa que podem ser observados a olho nu, gerando principalmente sinais de ondas superficiais com conteúdo espectral mais elevado, embora mais disperso em comparação aos eventos internos do vulcão. Estes eventos podem ser os fluxos de lava, fluxos piroclásticos, lahares, chuva de cinza, fumagças, entre outros fenômenos (Scarpa; Tilling, 2012; Houghton et al., 2015).

- **Fluxos piroclásticos (PYF).** Refere-se às nuvens quentes expelidas nas erupções explosivas, que podem incluir fragmentos de lava, rochas de vários tamanhos e gases a temperaturas superiores a 200°C. A coluna eruptiva pode ascender vários quilômetros de altura, enquanto os materiais piroclásticos mais densos descem pelas ladeiras devido à gravidade, alcançando velocidades superiores a 100 km/h (Houghton et al., 2015). Estes eventos representam um alto risco para as populações que estão próximas, dentro de um raio de 50km.
- **Lahares (LAH).** Material vulcânico, como rochas, cinzas e sedimentos, quando misturados com água, formam uma avalanche de lama vulcânica capaz de destruir objetos em seu caminho. Existem casos em que povoados inteiros foram cobertos e desapareceram. Isso geralmente ocorre quando a parte alta do vulcão contém neve ou geleiras, ou devido à presença de chuvas intensas. Os fluxos de lama, conhecido como lahares, podem percorrer distâncias de até 100 km e atingir velocidades de 50 km/h (Wassermann, 2012), representando um grande risco para as populações próximas ao vulcão. Em 1985, o vulcão *Nevado del Ruiz*, na Colômbia, derreteu o gelo do topo durante uma erupção, provocando um grande fluxo de lama que cobriu uma cidade inteira e resultou em 23.000 vítimas fatais (Voight, 1990).
- **Chuva de cinzas (AFL).** Formadas pelos gases e cinza expelidos na coluna eruptiva e caem quando esfriam na região limítrofe entre a estratosfera e a troposfera. Podem cobrir extensas áreas de terreno e cidades, causando o colapso de telhados e problemas respiratórios na população. As nuvens de cinzas podem ser transportadas pelo vento por grandes distâncias, chegando a centenas de quilômetros. Quando as nuvens de cinzas se misturam com chuva, podem desprender gases tóxicos ( $SH_2$ ,  $CO$ ,  $CO_2$  e  $SO$ ) originando a chuva ácida (Houghton et al., 2015).
- **Rios de lava (LAF).** Formados pelo magma que emerge para o exterior e desce a partir da cratera. Podem destruir o que estiver no seu caminho e causar incêndios ao redor devido às altas temperaturas (superiores a 1000°C) (Houghton et al., 2015). Não atingem altas velocidades, portanto, não representam um alto risco para as populações.

## 2.5 Monitoramento de vulcões ativos

As erupções vulcânicas são fenômenos naturais que podem representar um alto risco a população local. A energia liberada por uma erupção vulcânica pode equivaler a 20.000 bombas atômicas segundo o registrado e avaliado na erupção do vulcão Santa Helena em 1980 (Austin, 1986). Por isto, é fundamental que as autoridades públicas sejam responsáveis por estabelecer programas de vigilância da atividade vulcânica, com o objetivo de evitar desastres. Atualmente, esses programas integram várias técnicas e ferramentas que proporcionam a interpretação de informações, visando a predição de erupções (Scarpa; Tilling, 2012).

### 2.5.1 Registros sísmicos

Existem diversas metodologias tanto na aquisição e armazenamento de registros de sinais sísmicos quanto para o nível da instrumentação utilizada, assim como para a distribuição e o tipo de estações onde os instrumentos são alocados (Havskov; Alguacil, 2004). Os sensores sísmicos são colocados em locais estratégicos próximos à cratera do vulcão, procurando minimizar os efeitos de propagação, localização e ruído.

As redes de monitoramento geralmente contam com, no mínimo, 5 estações. O registro capturado pelos sensores sísmicos, chamado de sismograma, não quantifica diretamente as ondas geradas na fonte senão que corresponde à convolução temporal do sinal e a resposta ao impulso do instrumento que digitaliza as ondas sísmicas. Existem dois tipos de sensores em função da resposta ao impulso, os de banda estreita e os sensores de banda larga, segundo a banda espectral de interesse  $[f_L, f_H]$ .

- **Sensores de curto período ou banda estreita.** Com banda espectral de interesse a partir de  $f_L \leq 1$  Hz. A frequência de amostragem  $f_s$  para este tipo de sensores geralmente é 50 Hz.
- **Sensores de longo período ou banda larga.** Com banda espectral de interesse a partir de  $f_L \geq 1$  Hz. Com frequência de amostragem  $f_s$  até 200 Hz.

Scarpa e Tilling (2012), Houghton et al. (2015) fazem uma descrição detalhada dos tipos de sensores e da topologia das redes de estações vulcânicas. Existem sensores sísmicos que capturam unicamente a componente vertical ( $Z$ ) dos sinais de sismos, ou também aqueles que registram as componentes horizontais ( $NS$ ,  $EW$ ). A topologia da rede depende da área de cobertura, a localização e ao número de estações, dependendo do objetivo da obtenção de informação. Chamam-se de **redes amplas** aquelas que abrangem mais de 20 km de diâmetro, ideais para diferenciar entre a sismicidade tectônica da vulcânica, além de localizar eventos de fluidos profundos. Já as **redes menores** são mais adequadas para registrar eventos sismo-vulcânicos



superficiais de baixa amplitude, porém com alto conteúdo espectral, sendo menos susceptíveis aos efeitos de propagação, dispersão e atenuação. Wassermann (2012) indica que segundo a distribuição e localização dos sensores as redes de sensores sísmicos podem variar de formas diferentes, conforme segue:

- **Único sensor.** Forma utilizada em monitoramentos antigos ou ainda em lugares de difícil acesso e com recursos limitados. Embora a quantidade de informação adquirida seja reduzida, é possível realizar análises da energia espectral do sinal e a energia média acumulada do sismograma, como parte de um sistema rudimentar de monitoramento.
- **Arranjos sísmicos.** Consistem na instalação de sensores (de 6 a 15) em um área com diâmetro menor a 100 metros. Seu objetivo é identificar os padrões de propagação das ondas para definir a estrutura vulcânica superficial e localizar as fontes de sismicidade de eventos LPs.
- **Redes de arranjos.** Cada estação corresponde a um arranjo. Geralmente, é composta por sensores de banda larga para as três componentes. Essas redes ajudam a obter uma boa resolução e localização mais precisa dos eventos sísmicos.

### 2.5.2 Monitoramento sísmico

O estudo da sismologia vulcânica é composta por várias linhas de pesquisa devido à complexa estrutura heterogênea das diferentes zonas vulcânicas, além da dificuldade da modelagem dos fenômenos magmáticos e hidrotermais involucrados na agitação vulcânica. Atualmente, os sistemas de predição de erupções são baseados no monitoramento do incremento da atividade sísmica de eventos de longo período (Chouet et al., 1994; Chouet, 2003). Porém, existem outras linhas de pesquisa para abordar o estudo da sismologia vulcânica, segundo Chouet e Matoza (2013) estas podem ser:

- **Tomografias 3D de alta resolução.** Permite identificar a estrutura interna do vulcão e a existência de fluidos, câmaras e rachaduras. É usado o cociente de velocidades  $v_P/v_S$  correspondentes das ondas  $P$  e  $S$  tendo como premissa que as ondas  $S$  não se propagam através de líquidos, indicando assim a existência de câmaras magmáticas.
- **Características espaço-temporais de sismos LP.** Proporcionam informação para construir mapas de potência espectral, possibilitando inferir a ubicação e profundidade da origem do sinal, devido aos padrões distintos de propagação dos eventos LPs em diferentes estruturas geológicas. O estudo da sismologia abordando estes sinais (LP) é um método bastante confiável, pois, normalmente, precedem os episódios eruptivos, portanto, são considerados como precursores.

- **Dinâmica do magma.** Análises de informação do tensor momento em eventos sísmicos de período muito grande (*Very large period* - VLP). Os sinais VLP estão correlacionados com a dinâmica da fonte e transporte de material durante erupções vulcânicas.
- **Propriedades acústicas do magma e fluidos hidrotermais.** A análise espectral dos eventos sísmicos LP com chegada de onda com componentes dominantes em alta frequência permitem determinar as propriedades acústicas associadas com tubos de ressonância, identificando rachaduras preenchidas de fluidos quando a frequência dominante está correlacionado com a morfologia da cavidade e o tipo de fluido. O problema nesta linha de pesquisa é identificar quando a cavidade pode conter vários tipos de fluidos.
- **Contagem de eventos precursoros.** É um método bastante simples, no entanto, a maioria dos sistemas de alertas usam esta técnica, identificando o grau de agitação vulcânica associado. Atualmente, são aplicadas técnicas probabilísticas .

A interpretação dos sinais sísmicos proporciona informação que está associada com a dinâmica dos fluidos, porém isto requer estudar as propriedades físicas, químicas e geológicas, e, também, dos processos de interação e transformação dos diferentes fluidos vulcânicos.

## 2.6 Processo eruptivo

Quando a energia acumulada no interior do vulcão atinge um nível suficiente, ela se propaga para as camadas mais superficiais, interagindo com os fluidos de magma, gases, sistemas hidrotermais e a estrutura do edifício vulcânico (Chouet; Matoza, 2013). Como resultado da liberação de energia, a sismicidade vulcânica aumenta, com o magma e os gases vulcânicos procurando se abrir caminho através de fraturas e cavidades internas do vulcão (Houghton et al., 2015). O movimento e a pressão destes fluidos causam fraturas nas rochas e vibrações nas rachaduras, resultando em terremotos de altas frequências ou tremores vulcânicos contínuos que podem demorar minutos ou até semanas.

As taxas típicas de sismicidade de fundo costumam ser de algumas dezenas de eventos por dia, dependendo da localização e quantidade de estações sísmicas. No entanto, as taxas de sismicidade antes e durante as erupções podem variar em dezenas a centenas por dia e até mesmo por hora. Os prognósticos de erupções baseados no aumento da sismicidade têm sido bem-sucedidos, indicando que o nível da sismicidade está associado ao nível de atividade vulcânica com alta probabilidade de erupção, e que esse nível aumenta na presença de enxames sísmicos.

Os vulcões ativos passam por ciclos eruptivos de duração variável, conforme evidenciado por eventos históricos (Mount St. Helens 1980, Izu-Oshima 1986, Ito-oki 1989, Redoubt 1989–1990, Unzen 1991, Pinatubo 1991, Spurr 1992 e Galeras 1993) (Scarpa; Tilling; Mc-

Nutt, 1996). Esses eventos indicam a presença de uma série de terremotos vulcânicos, geralmente composta pelos seguintes componentes: inicialmente, ocorrem enxames de eventos de alta frequência, seguidos por um período de repouso relativo após o pico da atividade sísmica. Em seguida, ocorrem eventos de baixa frequência, seguidos por tremores vulcânicos e, finalmente, a erupção. Posteriormente, podem ocorrer terremotos profundos.


A Figura 11 indica o modelo genérico de atividade sísmica vulcânica, indicando as taxas de sismicidade para os diferentes tipos de eventos e processos dominantes na sequência temporal comum observada em diferentes vulcões. Segundo (Scarpa; Tilling; McNutt, 1996) os enxames de sismos VT apresentam maiores durações e têm uma alta taxa de falso alarme para erupção, enquanto os enxames de sismos de baixa frequência e tremores são mais curtos e levam a erupções com mais frequência. As variações da participação de sistemas hidrotermais, assim também como a composição do magma, temperatura, a taxa de fluxo e conteúdo volátil pode explicar as diferenças observadas na atividade vulcânica para diferentes vulcões. A Tabela 3 indica os fatores que tem influência nos processos vulcânicos.

Tabela 3 - Fatores que influenciam os processos vulcânicos

| <b>Fator</b>             | <b>Intervalo típico</b>                | <b>Observações</b>                                                                                                                                                 |
|--------------------------|----------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Temperatura do magma     | 800 - 1250°C                           | Influencia na viscosidade do magma, afetando a energia disponível para a ascensão da pluma de erupção                                                              |
| Água magmática           | 0.1 - 6 % H <sub>2</sub> O             | Controla a fragmentação do magma através do processo de vesiculação (formação de espaços vazios no magma)                                                          |
| Viscosidade do magma     | 10 <sup>2</sup> - 10 <sup>10</sup> P   | Determina as propriedades do fluxo do magma, da vesiculação e do crescimento das bolhas. Controla a ascensão e fuga de bolhas no magma.                            |
| Taxa da massa de erupção | 10 <sup>6</sup> – 10 <sup>9</sup> kg/s | A taxa de fluxo do magma no conduto de saída para o exterior é o fator mais importante.                                                                            |
| Água externa             | 0.01 - 0.5%                            | A fração de água externa que pode se misturar com o magma no duto de saída.                                                                                        |
| Conteúdo de cristais     | 0 - 50 %                               | Afeta a viscosidade em massa e, portanto, a reologia do magma (propriedades do fluxo, deformação pelas diferentes condições de temperatura, pressão e composição). |

Fonte: Processos vulcânicos em Enciclopédia de vulcões, (Houghton et al., 2015).

Figura 11 - Processo eruptivo em vulcões ativos



Fonte: Adaptação do Modelo genérico do ciclo eruptivo. (Scarpa; Tilling, 2012)

### 3 CLASSIFICAÇÃO DE SINAIS SISMO-VULCÂNICAS

Os sinais sísmicos apresentam propriedades particulares que devem ser consideradas com cuidado nos modelos de classificação. A variabilidade na frequência e na duração dos eventos sísmicos é particularmente notável e, muitas vezes, uma característica distintiva desses sinais. A variabilidade pode surgir tanto devido aos diferentes períodos de atividade vulcânica ao longo do tempo (Chouet et al., 1994; Saccorotti; Lokmer, 2021) quanto à ocorrência de eventos similares em vulcões diferentes (Malfante et al., 2018; Saccorotti; Lokmer, 2021).

Por outro lado, os sinais de sismos vulcânicos refletem diretamente a atividade interna dos vulcões, implicando que certos tipos de sinais podem ser mais predominantes. Para evitar o viés de classificação em relação às classes majoritárias sobre outras, os modelos de classificação automática devem lidar com o desbalanceamento na distribuição das classes.

Tendo em vista o contexto das características dos sinais sísmicos, é fundamental que a funcionalidade do modelo seja capaz de lidar com a variabilidade e o desbalanceamento das classes. Além disso, o modelo deve ser robusto para se manter estável diante de ruídos, do tamanho da base de dados e de dados atípicos (*outliers*), a fim de generalizar de forma consistente, adaptando-se a diferentes cenários e assegurando resultados consistentes e confiáveis.

#### 3.1 Técnicas de classificação de sinais de sismos vulcânicos

A classificação automática para sinais sísmicos teve origem no final dos anos 70, incentivada pela evolução dos algoritmos de detecção automática, visando no reconhecimento de padrões sísmicos, tanto em terremotos tectônicos quanto em sismos causados por explosões nucleares (Chen, 1978). Estudos conduzidos por Allen (1978), Anderson (1978) estudaram as ondas de chegada P e S em terremotos, trabalhos subsequentes continuaram esta linha de abordagem (Blandford, 1982; Farrell; CA, 1982; Faure; Soldano; Pyl, 1984; Liu, 1985).

Os trabalhos de Dowla, Taylor e Anderson (1990), Magotra et al. (1990), Wang e Teng (1995) foram pioneiros ao utilizar o modelo de rede neurais artificiais (ANNs) na classificação de sinais para distinguir sismos de origem natural e explosões artificiais. No contexto de sismos vulcânicos, Falsaperla et al. (1996), Carniel et al. (1996) também empregaram redes neurais para a classificação automática de terremotos vulcânicos na Itália, especificamente no vulcão

Stromboli, a fim de discriminar entre 4 classes de sismos. Esses modelos continuaram a ser aplicados como métodos de classificação no início do século XXI, com as contribuições dos trabalhos de Ezin et al. (2002), Scarpetta et al. (2005), Langer et al. (2006), que buscaram discriminar eventos de sismos vulcânicos de outros eventos externos que também geram sinais.

Também foram usados outros modelos de aprendizagem automático como as redes bayesianas para dados de registro contínuo (Orozco et al., 2006; Riggelsen; Ohrnberger; Scherbaum, 2007). As máquinas de vetores suporte (SVMs) (Langer et al., 2006; Apolloni et al., 2009; Curilem et al., 2014) ganharam destaque devido à sua simplicidade de projeção e implementação. Os modelos ocultos de Markov (HMMs), também se tornaram populares na comunidade científica, foram aplicados na discriminação de sinais de sismos de registro contínuo (Benítez et al., 2006; Ibáñez et al., 2009a; Cortés et al., 2009; Cárdenas-Peña; Orozco-Alzate; Castellanos-Dominguez, 2013) devido ao sucesso destes modelos em sinais de áudio e fala (Liu; Huang; Wang, 1998; Chan et al., 2002).

Trabalhos mais recentes têm adotado esquemas combinados de reconhecimento e classificação visando compensar algumas limitações dos modelos clássicos (Bueno et al., 2020; Manley et al., 2022). Outra abordagem é a aplicação de modelos adaptativos, Castro-Cabrera et al. (2021) consideraram a evolução das distribuições de dados na dinâmica dos processos vulcânicos em seu trabalho, o que pode induzir desvios de conceito nos registros sísmicos. Por sua vez, Falcin et al. (2021) treinou um modelo de floresta aleatória ao introduzir novas classes de sinais, permitindo que o modelo aprenda a discriminar conforme incorpora cada classe. Outros trabalhos propõem a ideia de ambiente de monitoramento multicanal (Spampinato et al., 2019; Titos et al., 2023).

A seguir, apresenta-se uma lista dos algoritmos de classificação de eventos sismo-vulcânicos mais usados na atualidade. Não se realiza uma análise aprofundada dos resultados e técnicas utilizadas, o qual está além do escopo deste capítulo. No entanto, a Tabela 4 apresenta um resumo dos trabalhos mais relevantes da literatura, dado o crescente interesse pela comunidade científica nesta área.

- Aprendizado baseado em instâncias: *k-Nearest Neighbors* (kNNs).
- Modelos discriminativos: Máquinas de vetor suporte (SVMs), Redes neurais artificiais (ANNs), Redes neurais recorrentes (RNNs), Redes neurais convolucionais (CNN).
- Modelos probabilísticos: Modelos de mistura gaussiana (GMMs), Modelos probabilísticos gráficos (PGMs), Modulos ocultos de Markov (HMMs).
- Combinação de métodos ou ensembles.

### 3.1.1 Aprendizado baseado em instâncias

O aprendizado baseado em instâncias (*Instance-Based-Learning* - IBL) são métodos fundamentados na ideia de que em situações semelhantes, as mesmas decisões são frequentemente tomadas. Neste caso, utiliza-se o critério de similaridade, conhecido como *lazy learning*, onde uma função de distância é empregada. Liu e Fu (1983), Galli et al. (2009), Cárdenas-Peña, Orozco-Alzate e Castellanos-Dominguez (2013) utilizaram o algoritmo *k-Nearest Neighbors* (kNNs) (Hodges; Fix, 1989) na classificação de sinais de terremotos, explosões artificiais e sismos vulcânicos.

Estes modelos possuem uma implementação bastante simples e são capazes de traçar fronteiras não lineares entre os dados. Além disso, estes modelos permitem o aprendizado incremental, possibilitando a inclusão de novas instâncias ou a apresentação de novos dados ao modelo. No entanto, a sua implementação requer alto custo de memória, avaliação lenta, e são modelos menos robustos em relação ao ruído.

### 3.1.2 Modelos discriminativos

Estes modelos proporcionam fronteiras de decisão de forma analítica por meio de uma função discriminante no espaço das características dos dados, que podem ser lineares ou não lineares. Na área da sismologia vulcânica, as Maquinas de Vetores Suporte (*Support Vector Machines* - SVMs) (Vapnik, 1999) e as Redes Neurais Artificiais (*Artificial Neural Networks* - ANNs) (McCulloch; Pitts, 1943; Rosenblatt, 1958) têm sido os modelos mais explorados nas últimas décadas.

#### 3.1.2.1 Máquinas de Vetores Suporte

Estes modelos também são conhecidos como "classificadores de margem máxima" devido à sua abordagem de encontrar o hiperplano de separação ideal. Este método envolve uma transformação do espaço original para um espaço de maior dimensão, a fim de garantir uma melhor separação entre as classes. Operam de maneira iterativa para atingir um mínimo global, sendo capazes de lidar com problemas lineares. No entanto, para a tarefa de discriminação multiclasse, são necessárias técnicas adicionais, e tanto o treinamento quanto a avaliação podem demandar um alto custo computacional. Masotti et al. (2008) aplicaram esses modelos na classificação de sinais de sismos vulcânicos, enquanto Curilem et al. (2014) utilizaram uma função de base radial gaussiana (RBF) no algoritmo. Langer et al. (2009), Lara-Cueva et al. (2016) compararam esse modelo com outros algoritmos de aprendizagem automático na tarefa de discriminação das classes de sismos vulcânicos.



### 3.1.2.2 Redes Neurais Artificiais

Os algoritmos de redes neurais são bio-inspirados. O modelo proposto por McCulloch e Pitts (1943), que é muito comum, cada neurônio representa uma combinação linear das entradas, e sua saída binária é discretizada por um limiar. Essas redes são consideradas aproximadores universais, pois podem modelar qualquer função contínua. Nas últimas duas décadas, esse modelo se tornou uma técnica padrão amplamente adotada não apenas na sismologia, mas também em outras áreas no tratamento de dados. O algoritmo clássico de treinamento em redes neurais é conhecido como *backpropagation* (Werbos, 1974), no qual o erro é propagado de volta pela rede para minimizar a diferença entre as saídas desejadas e as saídas obtidas, ao mesmo tempo em que se ajusta os pesos das conexões neurais para melhorar o desempenho da rede.

Existem diferentes arquiteturas de ANNs, a mais explorada na área da sismologia vulcânica tem sido a rede *Perceptron Multi-Camada* (*Multi layer Perceptron* - MLP) com os trabalhos de Falsaperla et al. (1996), Avossa et al. (2003), Pezzo et al. (2003), Scarpetta et al. (2005), Esposito et al. (2006), Langer et al. (2006), Langer et al. (2009), Curilem et al. (2009). Por outro lado, Esposito et al. (2013b) usou uma rede neural não supervisionada conhecida como Mapas auto-organizáveis (*Self-Organizing Maps* - SOMs) para discriminar sismos vulcânicos do tipo VT de deslizamentos e explosões artificiais. Por sua vez, Khattak et al. (2017), Titos et al. (2018b), Titos et al. (2018c) usaram arquiteturas mais profundas para classificação de sismos vulcânicos, usando redes recorrentes, como a rede de curta e longa memória (*Long Short Term Memory* - LSTM) para a análise de dados em sequências. Finalmente, Canario et al. (2020) usou redes convolucionais (*Convolutional Neural Networks* - CNNs) para a classificação das imagens dos espectrogramas dos sismos vulcânicos.

As ANNs, como modelos de classificação, tem a vantagem de serem flexíveis para abordar sistemas complexos, mesmo quando não há informações a priori ou as informações permanecem em estado latente, como é o caso dos sinais de sismos vulcânicos. Estes modelos conseguem separar classes em espaços não lineares de características e modelar relações complexas entre as variáveis de entrada e de saída. No entanto, os modelos mais profundos de redes neurais requerem bases de dados maiores para evitar o sobreajuste (*overfitting*) (Ben-David et al., 2010), a menos que a quantidade de parâmetros seja adequadamente regulada durante o treinamento. No próximo capítulo, este tema será abordado com mais detalhes quando for apresentada a proposta de caracterização e classificação de sinais de sismos vulcânicos.

### 3.1.3 Modelos probabilísticos

Os modelos probabilísticos de aprendizado automático compreendem um conjunto de algoritmos e técnicas que se baseiam na teoria da distribuição da probabilidade para abordar a

análise de dados e tomada de decisões. Os modelos gráficos expressam a relação entre as variáveis aleatórias por meio da conexão dos nós. Eles oferecem vantagens significativas, como a capacidade de lidar com a incerteza e fornecer uma medida de probabilidade para as variações. No entanto, também apresentam limitações e podem exigir recursos computacionalmente consideráveis.

### 3.1.3.1 Modelos de Misturas gaussianas

Estes algoritmos *Gaussian Mixture Models* (GMMs) (Li; Barron, 1999), estimam a probabilidade associada a cada classe. Eles se baseiam na suposição de que os dados de cada classe podem ser descritos por uma mistura de distribuições gaussianas. Cada componente gaussiano representa uma subpopulação dentro da classe e é caracterizado por um vetor de médias e uma matriz de covariâncias. A combinação desses componentes forma a mistura gaussiana que aproxima a distribuição dos dados coletados em cada classe. É importante escolher adequadamente o parâmetro das componentes gaussianas multivariadas para controlar a complexidade do problema e garantir um ajuste adequado do modelo aos dados (Wan et al., 2019). Alvarez et al. (2011), realizou a classificação de sinais de sismos vulcânicos, experimentando com 2, 4, 8 e 16 componentes gaussianas. Por sua vez, Cortés et al. (2014) encontrou que 4 componentes gaussianas é suficiente para se obter resultados eficientes de classificação.

Uma vantagem dos modelos GMMs é a sua capacidade de modelar distribuições multimodais, ou seja, quando os dados de uma classe possuem várias subpopulações distintas (Wan et al., 2019). Isso é especialmente útil ao analisar sinais de sismos vulcânicos, uma vez que esses sinais podem originar-se em vulcões diferentes, resultando em diferentes subpopulações de dados. Esses algoritmos podem se adaptar a uma ampla variedade de problemas de classificação quando várias componentes gaussianas são combinadas (Wan et al., 2019). Também são eficientes na detecção de anomalias ao identificar dados que se desviam das distribuições gaussianas aprendidas. No entanto, são algoritmos sensíveis ao método de inicialização, além de assumirem que os dados têm uma distribuição gaussiana, o que pode não ser compatível com todos os problemas.

### 3.1.3.2 Modelos probabilísticos gráficos

Esses modelos, chamados de *Probabilistic Graphical Models* (PGMs), possuem a vantagem de representar a interdependência probabilística por meio de grafos, nos quais cada variável é associada a um nó, e as arestas indicam o tipo de relação (Koller; Friedman, 2009). Existem duas vertentes principais para esse tipo de modelos: as redes bayesianas e os campos aleatórios de Markov. As redes bayesianas conseguem decompor a probabilidade conjunta como produtos de probabilidades condicionais entre os nós, permitindo assim modelar relações causais, lidar

com a incerteza e atualizar a tomada de decisões à medida que novas informações estão disponíveis (Song; Kolar; Xing, 2009). Riggelsen, Ohrnberger e Scherbaum (2007), utilizaram esse algoritmo para a discriminação de fluxos de dados sismológicos de forma sequencial.

Outra vantagem desse tipo de algoritmos inclui a capacidade de incorporar o conhecimento de especialistas na interpretação e generalização do modelo. No entanto, esses algoritmos podem ser computacionalmente custosos, principalmente quando envolvem muitas variáveis (Murphy et al., 2002). Além disso, determinar a estrutura correta do grafo pode ser um desafio, e decisões incorretas podem afetar a capacidade e eficiência do modelo.

### 3.1.3.3 Modelos ocultos de Markov

Esses modelos, *Hidden Markov models* (HMMs) (Baum; Petrie, 1966), são uma evolução das cadeias de Markov. Permitem modelar estruturas sequenciais por meio de uma topologia de S estados ocultos inter-conectados, resultando em um modelo estocástico duplo no espaço de características e no espaço do tempo (sequências). O treinamento do modelo é geralmente realizado por meio do algoritmo *Baum-Welch* (Baum et al., 1970).

A aplicação destes modelos é adequada para dados sequenciais e análises de séries temporais, pois eles têm a capacidade de modelar informações latentes dos dados. Não obstante, nem sempre é possível cumprir com todas as suposições do modelo nas situações práticas (Visser, 2011; Orozco-Alzate; Acosta-Muñoz; Londoño-Bonilla, 2012). Por exemplo, assumir que os estados são mutuamente independentes ou que os estados futuros dependem só do estado atual, pode afetar negativamente o desempenho do modelo (Zucchini; MacDonald, 2009; Visser, 2011). Além disso, esses modelos podem não ser adequados para dados com alta dimensionalidade ou de natureza complexa.

Na área da sismologia estes modelos também têm sido explorados devido as vantagens que oferecem para a análise de series temporais. Os pioneiros na aplicação desses modelos à classificação de sinais de sismos vulcânicos foram Benítez et al. (2006), Ibáñez et al. (2009a). Além disso, Cortés et al. (2009), Moreno (2015) também conduziram pesquisas usando esses modelos em diferentes vulcões, assim como Cárdenas-Peña, Orozco-Alzate e Castellanos-Dominguez (2013) no caso do vulcão Nevado del Ruiz na Colômbia.

### 3.1.4 Combinação de métodos ou ensembles

A combinação de sistemas de reconhecimento e categorização de sinais tem como objetivo aumentar a eficiência da classificação por meio de diversas estratégias e abordagens, permitindo que os modelos classificadores se complementem entre si.

Como exemplo desse modelo, está o trabalho de Venegas et al. (2019), que exploraram diferentes combinações de modelos de aprendizado de máquina para encontrar o mais adequado

na classificação de sinais de sismos vulcânicos. A ideia principal dos autores foi avaliar cinco combinações a fim de identificar a que maximize a métrica de Área Sob a Curva da Característica de Operação do Receptor (AUC-ROC). Por outro lado, Bueno et al. (2020), abordaram a classificação dos sinais de sismos vulcânicos usando o conceito de aprendizado profundo (*deep learning*) aplicando redes bayesianas para desenvolver um modelo que denominaram Redes Neurais Bayesianas (BNNs). Os autores destacam que esse conjunto de modelos permite abordar a incerteza associada às mudanças no estado de agitação nos vulcões, tornando o modelo adaptável a diferentes cenários eruptivos.

Tabela 4 - Visão geral dos trabalhos relatados

|                         | Autor                       | Classes                                                                       | Eventos/classe | Classificador          | Eficiência | Caracterização                                                     |
|-------------------------|-----------------------------|-------------------------------------------------------------------------------|----------------|------------------------|------------|--------------------------------------------------------------------|
| IBL                     | Liu and Fu (1983)           | Terremotos, Explosões artificiais                                             | 321/2          | kNN sintático          | 91%        |                                                                    |
|                         | Galli et al. (2009)         | Ruído, VT, LP                                                                 | 291/3          | kNN / Bayes            | 90%        |                                                                    |
|                         | Cárdenas-Peña et al. (2013) | HYB, LP, TR, VT                                                               | 948/4          | kNN                    | 76%        |                                                                    |
| Análises discriminativo | Masotti et al (2006)        | pré-eruptivo (PRE), fonte de lava (FON), eruptivo (ERU) e pós-eruptivo (POS). | 425/4          | SVM linear             | 94%        | STFT 1024 pontos                                                   |
|                         | Langer et al. (2009)        | pré-eruptivo (PRE), fonte de lava (FON), eruptivo (ERU) e pós-eruptivo (POS). | 425/4          | SVM e MLP              | 95%        | Espectrograma, vetor 62 componentes                                |
|                         | Lara-Cueva et al. 2016      | VT, LP, outros                                                                | 914/3          | SVM, árvore de decisão | 97%, 90%   | Características estatísticas, temporais, espectrais e escala (80). |
|                         | Curilem et al. (2014b)      | TR, LP, VT                                                                    | 1622/4         | SVM (rbf)              | 80%        | 6 características                                                  |
|                         | Curilem et al 2017          | VT, LP, TR                                                                    | 769/3          | SVM                    | 95%        | Algoritmo genético para 63 características                         |
|                         | Falsaperla et al (1996)     | 4 classes de Explosões eruptivas                                              | 75/4           | MLP                    | 89%        | função de autocorrelação e envelope                                |
|                         | Avossa et al. (2003)        | Explosão de dois tipos                                                        | 353/2          | MLP                    | 98%        | PCA 15 componentes                                                 |

Continua

Tabela 4 - Visão geral dos trabalhos relatados

| Análise discriminativo | Autor                   | Classes                                                                                      | Eventos/classe | Classificador | Eficiência   | Caracterização                                                     |
|------------------------|-------------------------|----------------------------------------------------------------------------------------------|----------------|---------------|--------------|--------------------------------------------------------------------|
|                        | Del Pezzo et al. (2003) | "VT e Explosões artificiais (pescadores) "                                                   | 30/2           | MLP           |              | LPC 7 coeficientes                                                 |
|                        | Scarpeta et al. (2005)  | VT e sismos locais                                                                           | 881/2          | MLP           | 98%          | LPC 6 coeficientes                                                 |
|                        | Esposito et al. (2006)  | Terremoto de explosão, deslizamento de terra e microterremores                               | 1159/3         | MLP           | 97%          | LPC no domínio da frequência e tempo 71 características            |
|                        | Langer et al. (2006)    | VT, LP, HYB, Regionais, queda de rochas                                                      | 6000/5         | MLP           | 80%          | Atributos estatísticos e função de autocorrelação                  |
|                        | Langer et al. (2009)    | Cuatro clases: pré-eruptivo (PRE), fonte de lava (FON), eruptivo (ERU) e pós-eruptivo (POS). | 425/4          | SVM e MLP     | 82%          | Espectrograma, vetor 62 componentes                                |
|                        | Curilem et al. (2009)   | LP, TR, TR enérgico                                                                          | 1033/3         | MLP           | 93%          | Atributos morfológicos, 6 (domínio do tempo), 2 (domínio da freq.) |
|                        | Esposito et al. (2013)  | VT, deslizamentos de terra, explosões artificiais e outros                                   | 1500/4         | SOM           | Não definido | LPC 10 componentes                                                 |

Continua

Tabela 4 - Visão geral dos trabalhos relatados

| Análise discriminativo | Autor                 | Classes                                                           | Eventos/classe | Classificador                                   |            | Eficiência         | Caracterização                                            |  |
|------------------------|-----------------------|-------------------------------------------------------------------|----------------|-------------------------------------------------|------------|--------------------|-----------------------------------------------------------|--|
|                        | Canário et al. 2020   | VT, LP, Tr, Tc                                                    | 3592/4         | CNN, LSTM                                       |            | 96%, 95%           | Wavelet Morlet (transformada imagens)                     |  |
|                        | Mousavi et al 2016    | Superficiais, profundos                                           | 4712/2         | Regressão MLP                                   | Logística, | 88%, 91%           | 40 recursos no domínio do tempo e freq.                   |  |
|                        | Giacco et al. 2009    | Deslizamentos de terra, terremoto explosão, microtremor vulcânico | 1159/3         | SVM e MLP                                       |            | 99% y 98%          | Domínio do tempo e freq. 71 características (6 LPC coef.) |  |
|                        | Bueno et al. 2019     | HF, LF, MX (mixto) para 6 períodos de atividade vulcânica         | 91496/3        | DL-BNN                                          |            | 92%%               | LFCC (13 coef)                                            |  |
|                        | Titos et al. (2018)   | LP, VT, TR, EX, Lava, RE, ruído                                   | 9332/7         | Autoencoder + DNN, MLP, SVM, floresta aleatória |            | 94%, 93%, 92%, 93% | Características estadísticas + LPC (5 componentes)        |  |
|                        | Venegas et al. 2019   | VT e LP                                                           | 668/2          | SVM + kNN, MLP + floresta aleatória             |            | 95%                | 84 características 13 (tempo), 21 (freq), 50 (escala)     |  |
|                        | Nakano Sugiyama, 2022 | TC , Eruptivos e não eruptivos                                    |                | CNN 1D y 2D                                     |            |                    | imagem 64x64 pixels<br>espectral                          |  |

Continua

Tabela 4 - Visão geral dos trabalhos relatados

| Autor                       | Classes                                                                                               | Eventos/classe | Classificador                     | Eficiência    | Caracterização                                    |
|-----------------------------|-------------------------------------------------------------------------------------------------------|----------------|-----------------------------------|---------------|---------------------------------------------------|
| Khattak, et al.             | VT e LP                                                                                               | 133/2          | ANN+Cartesian Genetic programming | 83%           | 42 características = 5 LPC, 12 wavelet, 25 outros |
| Titos et al. (2019)         | VT, LP, TR, HYB                                                                                       | 971/4          | RNN, LSTM, GRU                    | 90%, 94%, 92% | LPC, LFB                                          |
| Álvarez et al 2011          | VT, LP, TR harmônico, TR pulsante, TR espasmódico, colapsos, quedas de rochas, lahars, explosões e TL | 475/10         | GMMs 2,4,8 e 16 gaussianas        | 86%           | DFS aplicado a coeficientes cepstrais             |
| Cortés et al 2014           | HYB, LP, VT, ruído                                                                                    | 328/4          | GMMs                              | 92%           | DFS aplicado a LFCC 39 componentes                |
| Riggelsen et al 2007        | sismos, ruído                                                                                         | 572/2          | Dynamic bayesian network (DBNs)   | 95%           | Transformada wavelet continua                     |
| Benítez et al 2007          |                                                                                                       |                |                                   |               |                                                   |
| Hoogenboezem (2010)         | LP, RE(regional), TL(local), VT                                                                       | 532/4          | HMM , Parzen                      | 92%           | PCA 15 componentes                                |
| Cárdenas-Peña et al. (2013) | HYB, LP, TR, VT                                                                                       | 948/4          | HMM                               | 88%           |                                                   |
| Ibáñez et al 2009           | TR, explosão vulcânica                                                                                | 1048/2         | HMM                               | 84%           | LFCC                                              |

Continua

Classificadores probabilísticos



Tabela 4 - Visão geral dos trabalhos relatados

| Autor              | Classes                                                                                  | Eventos/classe | Classificador | Eficiência | Caracterização |
|--------------------|------------------------------------------------------------------------------------------|----------------|---------------|------------|----------------|
| Cortés et al 2009a | TR harmônico, TR pulsante,<br>TR espasmódico, VT, LP,<br>EXP, RE, COL, Lahares,<br>ruído | 4687/10        | HMM           | 81%        | LFCC           |
| Cortés et al 2009b |                                                                                          | 6788/10        | HMM           | 78%        | LFCC           |

Fonte: Elaborado pelo autor.

Fim da tabela

### 3.2 Técnicas de Caracterização

A representação compacta dos sinais de sismos vulcânicos, por meio do processo de caracterização, é fundamental para tornar a tarefa de reconhecimento automático mais eficiente. Essa representação dos sinais permite a redução da dimensionalidade, transformando o sinal em um vetor de características capaz de armazenar as informações subjacentes mais relevantes contidas nos sinais, ao mesmo tempo que elimina a informação redundante e também o ruído, sem perda significativa. Isso otimiza o processo de classificação.

A necessidade de caracterização surge como resposta ao conceito da "maldição da dimensionalidade" (*curse of dimensionality*) (Bellman; Roth, 1986), devido à crescente dificuldade de trabalhar com dados em espaços de alta dimensão. À medida que o número de dimensões aumenta, é necessária uma maior quantidade de dados para preencher o espaço de forma eficaz (Bellman; Dreyfus, 2015). A dispersão dos dados em espaços de alta dimensão complica a identificação de padrões e as relações estatísticas entre eles. Um número insuficiente de instâncias pode resultar no fenômeno de sobreajuste durante o treinamento do modelo de aprendizado (Bishop et al., 1995).


Outras razões que justificam a aplicação de métodos para reduzir a dimensão em sinais de sismos vulcânicos foram apresentadas por Cortés et al. (2015), os quais indicaram que a interpretação das características é mais eficiente. Além disso, a capacidade de generalização dos modelos de classificação aumenta, dado que se evita a adaptação do modelo de aprendizagem aos dados. Também, há uma redução no custo computacional tanto durante o treinamento quanto na classificação.

Existem dois métodos básicos para reduzir a dimensionalidade. Um desses métodos é baseado na seleção de recursos, onde se forma um subconjunto a partir do conjunto inicial, contendo apenas os recursos mais eficazes. O outro método refere-se à transformação de recursos ou características, onde o espaço de características original é transformado para um espaço de menor dimensão, a Figura 12 indica a diferença entre estes dois métodos. A boa escolha das características deve ter como base a máxima relevância e mínima redundância. Geralmente, a capacidade de descrever os dados é dada pela capacidade de separação dos dados por classes.

#### 3.2.1 Seleção de características

O objetivo deste método é formar um subconjunto a partir dos recursos mais representativos, seguindo algum critério estabelecido. Neste método, trabalha-se sobre o mesmo espaço original de características. Em sinais de sismos vulcânicos, tem-se explorado características de natureza geofísica, que fornecem informação sobre a natureza dos eventos. Geralmente, esses recursos são usados por especialistas na classificação manual supervisionada. Também exis-

Figura 12 - Estratégias básicas para a redução da dimensionalidades para representar dados



Fonte: Adaptado de (Hoogenboezem, 2010).

tem características de natureza estatística, onde o sinal é considerado como uma serie temporal que pode ser descrito por meio de parâmetros estatísticos da forma de onda e seu conteúdo em frequência.


### 3.2.1.1 Características de natureza geofísica

As características geofísicas podem proporcionar informação sobre as fontes de geração e do meio onde os sinais se propagam, a energia, localização, evolução temporal, entre outras. São úteis para a classificação manual feita por especialistas. Normalmente, a taxa de reconhecimento ao empregar esse método de seleção de características não demonstra resultados satisfatórios, razão pela qual costumam ser utilizadas como parte de vetores com outro tipo de características (vetores mistos) (Orozco-Alzate; Acosta-Muñoz; Londoño-Bonilla, 2012; Castro-Cabrera et al., 2014).

Álvarez et al. (2009), propuseram um esquema de 13 características que denominaram *geo\_13*, sendo 6 correspondentes ao domínio do tempo e 7 no domínio da frequência como pode ser observado na Figura 13 e se indica na Tabela 5. Segundo Cortés et al. (2015), estas características podem ser agrupadas nas seguintes categorias:

- Impulsividade do início do sinal: refere-se à soma acumulada normalizada do valor absoluto do sinal que caracteriza o comportamento do início do evento. As características *t.20*, *t.50*, *t.80* e *t.Slo* fazem parte desta categoria.
- Modelagem espectral: refere-se à soma acumulada normalizada do espectro de densidade de potência (PSD). Usado para determinar o conteúdo de frequência do evento. As características *f.20*, *f.50*, *f.80* e *f.Slo* fazem parte desta categoria.

Figura 13 - Características geofísicas para dois eventos sísmicos (VT e LP), indicando as características no domínio do tempo e no domínio da frequência (terceira linha), para ambas formas de onda (VT na primeira linha e LP na segunda linha)



Fonte: Utilidade dos recursos geofísicos (Cortés et al., 2015).

- Periodicidade e harmônicos: O segundo pico das funções de autocorrelação normalizadas no domínio do tempo é usado para enfatizar a periodicidade do evento (característica *t.nac*). Da mesma forma no domínio da frequência (característica *f.nac*).
- Energia: A energia máxima do envelope da forma de onda (característica *t.Max*) e a energia máxima do envelope do PSD (característica *f.Max*).
- Recurso LPF.err: indica a semelhança entre o PSD e forma de passagem de baixa frequência no espectro.

Tabela 5 - Características da natureza geofísica

| Identificação | Característica                         | Descrição                                         |
|---------------|----------------------------------------|---------------------------------------------------|
| $t.20$        | posição do 20% da amplitude            | envelope de chegada                               |
| $t.50$        | posição do 50% da amplitude            | envelope da amplitude                             |
| $t.80$        | posição do 80% da amplitude            | envelope da cauda                                 |
| $t.Slo$       | inclinação da amplitude: $t.70 - t.30$ | impulsividade do sismograma                       |
| $t.Max$       | posição temporal da amplitude máxima   | envelope da máxima energia                        |
| $t.nac$       | 2do pico da autocorrelação normalizada | periodicidade                                     |
| $f.20$        | freq. do 20% da energia normalizada    | espectro: banda inferior                          |
| $f.50$        | freq. do 50% da energia normalizada    | espectro: banda media                             |
| $f.80$        | freq. do 80% da energia normalizada    | espectro: banda alta                              |
| $f.Slo$       | inclinação do espectro: $f.70 - f.30$  | espectro: largo de banda                          |
| $f.Max$       | freq. da máxima energia espectral      | espectro: energia máxima                          |
| $f.nac$       | 2do pico da autocorrelação normalizada | frequências ressonantes                           |
| $LPF.err$     | erro no espectro de baixa frequência   | forma de passagem de baixa frequência no espectro |

Fonte: Esquema de parametrização geofísica, (Álvarez et al., 2009).

Além das características geofísicas mencionadas no esquema geo\_13, existem outros trabalhos que determinam descrições geofísicas para construir sistemas de classificação automática (Castro-Cabrera et al., 2014), como:

- Autocorrelação espacial (Aki et al., 1978).
- Análises de frequência e número de onda (Kvaerna; Ringdal, 1992).
- Sonograma discretizado (Ohrnberger, 2001).
- Medidas espectrais do elipsoide de polarização (Pinnegar, 2006).
- Medidas de localização: latitude, azimut, epicentro, profundidade e intensidade (Papoula; Drosou; Koukouvinos, 2013).

### 3.2.1.2 Características de natureza estatística

Para descrever sinais de sismos vulcânicos, diversos parâmetros estatísticos são considerados, frequentemente utilizados para caracterizar series temporais. Esses parâmetros podem ser calculados tanto no domínio do tempo quanto no domínio da frequência. Uma análise descritiva desses parâmetros foi conduzida por Lara-Cueva et al. (2015) e é descrita a seguir, em primeiro lugar, se faz uma lista das características no domínio do tempo:

- Valor Quadrático Médio (RMS): proporciona a medida da amplitude média de um sinal e se calcula como na Equação 1.

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N |x[n]|^2} = \sqrt{\frac{x_1^2 + x_2^2 + x_3^2 + \dots + x_N^2}{N}} \quad (1)$$

- Diferença entre máximo e mínimo: este parâmetro permite avaliar a amplitude dos valores alcançados.
- Relação entre valores pico e RMS: este parâmetro é usado para avaliar a amplitude e a variabilidade do sinal, a fim de identificar picos abruptos. O cálculo é realizado como mostrado na Equação 2.

$$Ratio_{L_{\infty}-RMS} = \frac{\|x[n]\|_{\infty}}{\sqrt{\frac{1}{N} \sum_{n=1}^N |x[n]|^2}} \quad (2)$$

- Energia: proporciona informação sobre a intensidade do evento. O cálculo é realizado conforme mostrado na Equação 3.

$$E_x = \sum_{n=-\infty}^{\infty} |x[n]|^2 \quad (3)$$

- Densidade de cruzamento por zero: este parâmetro calcula a quantidade de vezes em que duas amostras consecutivas diferem em sinal ou são definidas como zero.
- Curtoses: refere-se à concentração de dados em torno da média da distribuição. O cálculo é realizado como mostrado na Equação 4

$$k = \frac{\frac{1}{n} \sum_{i=1}^n (x[n] - \bar{x})^4}{(\frac{1}{n} \sum_{i=1}^n (x[n] - \bar{x})^2)^2} \quad (4)$$

Em que:

$x[n]$  é a variável discreta, cada amostra do sinal,

$\bar{x}$  é a média dos valores da variável discreta,

$N$  é o número total de amostras,

em todas as equações.

No domínio da frequência, usando a transformada de Fourier de curta duração (STFT), os sinais de sismos vulcânicos são plotados em função da frequência, onde podem ser apreciadas outras características, tais como:

- Máximo: Valor máximo do conteúdo espectral.
- Média: Valor médio da amplitude do conteúdo espectral.
- Valores máximos na faixa de frequência de 20 Hz a 30 Hz.
- RMS, calculado usando a Equação 1 no espectro.
- Relação entre valores pico e RMS calculado usando a Equação 2 no espectro.
- Energia, calculada usando a Equação 3 no espectro.
- Segundo e terceiro pico dos valores de frequência.
- Densidade espectral de Potência (PSD): o que permite identificar os valores máximos em tempo e amplitude e as frequências dominantes, ou bandas de frequências relevantes .

Pérez et al. (2020), compilaram uma lista de 84 características estatísticas que foram calculadas nos domínios do tempo, frequência e escala para o repositório de dados de sinais de sismos vulcânicos correspondentes ao vulcão Cotopaxi no Equador.

### 3.2.2 Transformação de características

A redução da dimensionalidade é resultado da transformação do espaço de características original em outro onde a informação seja menos esparsa, e assim, permitir a projeção das características para um espaço de menor dimensão, que permita extrair informações discriminativas dos sinais.

Na área de sismologia vulcânica, muitos autores optam por métodos que se baseiam na transformada espectral do sinal. Diferentes técnicas foram utilizadas, incluindo a Transformada de *Fourier* em tempo discreto (DTFT), a Transformada Rápida de *Fourier* (FFT) e a Transformada Discreta de Cosseno (DCT), que servem como base para analisar o conteúdo de frequência e determinar os componentes cepstrais (Ibáñez et al., 2009a; Castro-Cabrera et al., 2014). Além disso, na literatura, também encontram-se trabalhos que exploraram a Transformada de *Hilbert* (Jousset et al., 2011; Gao; Huang; Cladouhos, 2023), e a Transformada *wavelet* (Benbrahim et al., 2007; Brusil et al., 2019; Taylor et al., 2011), como métodos para extrair componentes que possam caracterizar os sinais e, assim reduzir a dimensionalidade.

Por outra parte, a partir da Transformada cepstral, comumente utilizada no processamento de sinais para analisar informações relacionadas à periodicidade e à estrutura espectral do sinal, é possível calcular os coeficientes cepstrais. Esses coeficientes são obtidos a partir da magnitude logarítmica sobre a transformada rápida de *Fourier* do sinal. Esse vetor de características

está relacionado à distribuição estatística das características espectrais do sinal (Oppenheim; Schafer, 2004).

Existem diferentes tipos de coeficientes cepstrais como métodos de extração de características, principalmente usados em sinais de fala e áudio. Os Coeficientes Cepstrais na escala de *Mel* (MFCC) (Davis; Mermelstein, 1980a) foram os primeiros calculados. A partir deles, surgiram outros conceitos, como os Coeficientes Cepstrais na escala de *Mel* (MFSC), os Coeficientes Cepstrais de Frequência Linear (LFCC), os Coeficientes Cepstrais de Predição Linear (LPCC), Os Coeficientes Cepstrais de Predição Linear Percentual (PLP) e os Coeficientes Cepstrais na escala de *Gammatone* (GFCC).

Na caracterização de sinais de sismos vulcânicos, os métodos mais explorados têm sido os MFCC, conforme demonstrado nos trabalhos de Cortés et al. (2009), Ibáñez et al. (2009a). Esses métodos utilizados como parte do pré-processamento dos sinais de sismos vulcânicos para posterior utilização em classificadores que empregaram HMMs. Por outra parte, também foram calculados LFCC para a representação desse tipo de sinais, como evidenciado nos trabalhos de Benítez et al. (2006), Ibáñez et al. (2009b), Cárdenas-Peña, Orozco-Alzate e Castellanos-Dominguez (2013). Geralmente, o vetor de coeficientes é composto por 13 elementos, além das primeiras e segundas derivadas de cada componente, o que proporciona informações sobre as variações sutis no sinal e a aceleração das mudanças.

Além das transformações e extração de características mencionadas, existem outras técnicas que também aplicam transformações no espaço dos recursos no processamento de sinais. Entre os mais comuns encontram-se a representação do sinal em Coeficientes de Predição Linear (LPC) (Makhoul, 1975), que modela a relação linear entre as amostras sucessivas de um sinal, sua predição e a representação dessa predição. Essa técnica é frequentemente usada na compressão de áudio e síntese de voz. Outra técnica é a Análise de Componentes Principais (PCA) (Hotelling, 1933), usada para encontrar os principais componentes em um conjunto de dados multivariado, útil para eliminar de redundâncias. Além disso, a Análise de Componentes Independentes (ICA) (Hyvärinen; Oja, 2000), que é capaz de decompor um conjunto de dados em componentes que não estão estatisticamente correlacionados, é utilizada para separar sinais de diferentes fontes. Por fim, o Modelo de Descomposição Empírica (EMD) (Huang et al., 1998), decompõe o sinal em componentes que são intrinsecamente dependentes da escala e do tempo, denominados *Intrinsic Mode Functions* (IMF).

No processamento de sinais de sismos vulcânicos, a literatura indica diversos trabalhos que aplicaram essas técnicas na caracterização de sinais. Por exemplo, Pezzo et al. (2003), Scarpetta et al. (2005), Esposito et al. (2013a), Bhatti et al. (2016), Curilem et al. (2016) utilizaram os LPC como parte do pré-processamento para a extração de recursos e classificação vulcano-



sísmica. Isso se deve à capacidade do LPC de ser aplicado independente da duração dos eventos, tornando-o uma técnica viável.

Outros trabalhos, como Taylor et al. (2011), Unglert e Jellinek (2016), Lara et al. (2020), Stähler e Sigloch (2014), aplicaram a PCA para reduzir a dimensão dos sismogramas, visando facilitar a posterior classificação. Além disso, a técnica EMD também foi explorada em pesquisas, como aquelas realizadas por Herrera, Han e Baan (2014), Lara et al. (2020), com o objetivo de revelar informações tempo-frequência que pode permanecer ocultas no espectro de *Fourier*.

## 4 METODOLOGIA

Este capítulo tem o objetivo de descrever a configuração experimental adotada durante o desenvolvimento deste trabalho. Inicialmente, será apresentada uma descrição dos bancos de dados utilizados e do pré-processamento realizado para a adequação e padronização dos dados, preparando o caminho para a implementação das técnicas de caracterização, que serão fundamentais para o processo de classificação dos dados.

As diferentes técnicas de caracterização, utilizadas como métodos de representação compacta por meio das características mais relevantes dos sinais, serão exploradas neste capítulo. Além disso, será detalhada a arquitetura da rede neural escolhida como modelo de classificação, incluindo a especificação dos hiper parâmetros selecionados.

A linha de configuração experimental também será explicada, descrevendo como os dados foram abordados no domínio do tempo e da frequência. A divisão dos dados em conjuntos de treinamento, teste e validação, será indicada, bem como o processo de treinamento e validação escolhido para avaliar o desempenho do modelo. Finalmente serão discutidas as métricas utilizadas para este propósito.

### 4.1 Banco de dados

Esta pesquisa foi conduzida com base em dois conjuntos de dados. O primeiro corresponde ao vulcão Galeras, fornecido pelo Observatório Vulcanológico e Sismológico de Pasto do Serviço Geológico Colombiano. Para o desenvolvimento experimental, foram disponibilizados 2205 sinais de sismos vulcânicos, dos quais 1736 são sinais VT, 402 sinais LP e 67 correspondem a sinais sísmicos do tipo TOR. Estes eventos sísmicos correspondem à atividade vulcânica registrada entre julho de 2004 a dezembro de 2010. O segundo conjunto de dados foi cedido pelo Observatório Vulcanológico Etneo (seção Catânia) do Instituto Nacional de Geofísica e Vulcanologia da Itália, que forneceu 126587 sinais correspondentes ao vulcão Etna, todos eles do tipo VT, e 11133 sinais do tipo LP provenientes no vulcão Vulcano, nas Ilhas Eólias da Itália.


Os sinais sismo-vulcânicos são captados por equipamentos com sensores que operam de forma contínua. Assim, cada evento é identificado, delimitado e extraído. Cada sinal de sismo corresponde a uma série temporal formada por uma sequência de dados de amplitude registrados de forma periódica, conhecidos como amostras do sinal. A frequência de amostragem do sinal determina a quantidade de amostras capturadas do sinal contínuo a cada segundo, resultando em uma representação em tempo discreto. Nos sinais de sismos vulcânicos nos conjuntos de dados

dos vulcões Galeras, Etna e Vulcano, a frequência de amostragem é de 100Hz, o que significa que a cada segundo foram registradas 100 amostras de amplitude. Essa escolha baseia-se no conhecimento prévio das características dos sinais deste tipo, seguindo o Teorema de Nyquist-Shannon (Nyquist, 1928; Shannon, 1949).


Quanto à distribuição das classes nas bases de dados, ambas exibem um desequilíbrio, com a classe VT sendo majoritária em ambos os casos, seguida pela classe LP, enquanto o tipo de sismos TOR representa a classe minoritária

Quanto à distribuição das classes nas bases de dados, ambas exibem um desequilíbrio, com a classe VT sendo majoritária em ambos os casos, seguida pela classe LP, enquanto o tipo de sismos TOR representa a classe minoritária. A duração dos eventos sísmicos é bastante variada no conjunto de dados do vulcão Galeras, com eventos que duram de 8 a 100 segundos, exceto nos sinais LP, que têm 3000 amostras, correspondendo a 30 segundos. Por outro lado, os sinais LP originados no vulcão Vulcano têm uma duração de 16 segundos, enquanto os sinais VT do vulcão Etna têm 3000 amostras, significando uma duração de 30 segundos. Isso pode ser observado nos histogramas da Figura 14 para os conjuntos de dados do vulcão Galeras, Etna e Vulcano.

Figura 14 - Histograma de distribuição das classes e duração dos eventos sísmicos



(a) Histograma vulcão Galeras



(b) Histograma vulcões Etna e Vulcano

Fonte: Elaborado pelo autor

#### 4.1.1 Adequação dos dados

Os eventos sísmicos requerem um processo de adequação e padronização para eliminar ruído e garantir que todos os dados apresentem um formato que possibilite a comparação equitativa das informações contidas nos sinais.

#### 4.1.1.1 Duração dos eventos

O primeiro passo na adequação dos dados foi padronizar a duração dos eventos. Dado que a maior parte da energia frequencial dos eventos se concentra nas 3000 primeiras amostras e, considerando que já havia eventos com essa duração, optou-se por uniformizar a duração de todos os eventos para 3000 amostras. Nos casos em que os eventos tinham durações menores, optou-se por adicionar zeros tanto no início quanto no final do evento para completar 3000 amostras.

#### 4.1.1.2 Filtragem dos sinais

O processo de registro dos sinais sísmicos pode ser afetado por ruído ambiental, pela instrumentação de aquisição dos sinais, por fenômenos geofísicos e pelas condições locais do vulcão, resultando na contaminação dos sinais por baixas frequências. Devido a isso, aplicou-se um filtro *Butterworth* para remover frequências muito baixas que poderiam distorcer a informação tanto no domínio do tempo como da frequência. A função de transferência do filtro de ordem  $n$  e frequência de corte  $W_c$  é dada pela Equação 5.

$$H(z) = \frac{1}{\sum_{k=0}^n b_k z^{-k}} \quad (5)$$

Em que:


$z^{-1}$ , indica o retardo no domínio  $z$ , típico em sinais discretos,

$n$ , corresponde à ordem do filtro Butterworth, ou seja, o número de polos do filtro,


$b_k$ , são os coeficientes do filtro.

A filtragem dos sinais foi aplicada com o intuito de eliminar as frequências inferiores a 1 Hz que poderiam interferir na interpretação dos sinais. A ordem do filtro escolhida foi 5, não houve preocupação em escolher uma ordem par ou ímpar, uma vez que a fase do filtro não é linear. A escolha de uma ordem relativamente baixa atende às condições de atenuação na frequência de corte, evitando distorções na forma de onda. A Figura 15 apresenta um sinal antes e depois da aplicação do filtro, bem como o espectro resultante do sinal.


Figura 15 - Filtragem dos sinais de eventos sísmicos



(a) Sinal VT sem filtro



(b) Sinal VT filtrado



(c) Espectro

Fonte: Elaborado pelo autor

#### 4.1.1.3 Normalização dos sinais

Os sinais filtrados foram normalizados com o objetivo de possibilitar uma comparação imparcial da informação contida, independente dos valores de amplitude originais. Foi empregada a técnica de normalização *min-max* para dimensionar os sinais a uma amplitude relativa entre 0 e 1. Essa normalização impede que características nos sinais com magnitudes maiores dominem sobre aquelas com magnitudes menores, em que informações significativas e representativas nos sinais podem se ver ofuscadas pelas amplitudes absolutas (Titos et al., 2018c). Dessa forma, os algoritmos a serem utilizados na transformação e extração de recursos convergem de maneira eficiente.

## 4.2 Caracterização dos sinais de sismos vulcânicos

Para a classificação e rotulagem de eventos sísmicos de origem vulcânica, trabalhar diretamente com as amostras captadas pelo sensor sísmico não é adequado. Torna-se necessário o uso de algoritmos capazes de extrair informações relevantes do sinal, minimizando o impacto do ruído e eliminando redundâncias para reduzir a dimensionalidade dos dados (Vapnik, 1999; Hastie et al., 2009). O objetivo é caracterizar o sinal através de um conjunto de valores que sejam mais representativo e úteis para uma tarefa de classificação posterior.

Este trabalho propõe caracterizar o sinal por meio de um conjunto de parâmetros ou valores, utilizando quatro técnicas distintas: PCA, LPC, LFCC e o Autoencoder Dual de Características (DAF), que é a técnica proposta por esta pesquisa. A ideia central é explorar esses métodos de caracterização para identificar qual deles é capaz de extrair características comuns em sinais de vulcões diferentes. Em outras palavras, busca-se a extração de padrões presentes nos sinais em diversos cenários vulcânicos, possibilitando que o modelo de classificação seja capaz de prever as classes de sinais de vulcões distintos daquele para o qual o modelo foi treinado, com o auxílio de uma técnica de caracterização que independe do contexto vulcânico.

### 4.2.1 Análises de Componentes Principais (PCA)

A técnica de redução da dimensionalidade conhecida como Análise de Componentes Principais PCA (Hotelling, 1933; Pearson, 1901), destaca-se como um algoritmo amplamente utilizado para este propósito. Esta técnica consegue lidar com informações correlacionadas, devido que a informação essencial nem sempre se encontra em uma variável individual, mas sim em como as variáveis mudam umas em relação às outras. As correlações entre as variáveis resulta em uma descrição mais útil do que as variáveis individuais.

Para compreender a aplicação desta técnica é necessário conhecer os conceitos básicos sobre PCA. Seja  $\mathbf{X} \in \mathbb{R}^{m \times n}$  a matriz de dados brutos, com  $m$  eventos sísmicos previamente normalizados (linhas) e  $n$  as amostras do sinal (colunas). A Equação 6 fornece a matriz de correlação de  $\mathbf{X}$ . Usando um algoritmo de decomposição (geralmente o algoritmos NIPALS ou o algoritmos de decomposição singular (SVD)) a matriz  $\mathbf{X}$  é decomposta como se indica na Equação 7.

$$\text{cov}(\mathbf{X}) = \frac{\mathbf{X}^T \mathbf{X}}{m - 1} \quad (6)$$

$$\mathbf{X} = t_1 p_1^T + t_2 p_2^T + \dots + t_k p_k^T + E \quad (7)$$

Em que:

$cov(\mathbf{X})$ , é a matriz de covariânciaa do conjunto de dados  $\mathbf{X}$ ,

$t_i$  corresponde aos vetores de pontuação, indicando a variabilidade da matriz original representada na componente  $i$

$p_i$  são os vetores de carga e correspondem aos autovetores da matriz de covariância, cada  $\lambda_i$  é uma medida da quantidade da variância correspondente ao autovetor  $p_i$ ,

$t_i p_i^T$  representa portanto a contribuição específica da componente principal  $i$  na reconstrução da matriz original  $\mathbf{X}$ ,

$E$  é a matriz residual que representa a variabilidade não explicada pelas componentes principais na decomposição. Refere-se à diferença entre a matriz original e a reconstrução a partir das componentes principais.

Portanto, o objetivo da PCA é reduzir o conjunto original a  $k$  componentes principais. Os fatores de pequena variação restantes são consolidados na matriz residual  $E$ . Os vetores de carga ( $p_i$ ) são ortogonais ( $p_i^T p_j = 0$  para  $i \neq j$ ,  $p_i^T p_j = 1$  para  $i = j$ ), contendo a informação de correlação entre as variáveis, e portanto, são considerados como componentes principais que podem descrever com precisão as principais variações nos dados.

Neste trabalho de pesquisa foram calculados 35 componentes principais para conservar o 90% da variabilidade nos dados originais.

#### 4.2.2 Codificação de Predição Linear (LPC)

A técnica LPC (Makhoul, 1975) possui aplicações na modelagem e compressão de sinais com altas taxas de compressão. Além disso, é amplamente utilizada na projeção e aproximação de filtros, análise espectral e, como o próprio nome sugere, na predição e extrapolação de sinais.

No processamento de sinais, este tipo de abordagem é aplicado como um modelo auto regressivo (AR), que pode ser visualizado como a saída de um filtro só-polos, conforme indicado pela Equação 8.

$$H(z) = \frac{G}{1 - \sum_{k=1}^p a_k z^{-1}} \quad (8)$$

Em que:

$H(z)$ , corresponde à função de transferência do sistema,

$G$ , representa o ganho do sistema,

$p$ , indica a ordem do filtro só-polos,

$a_k$ , refere-se aos coeficientes do filtro.

Para resolver o sistema a Equação 9 indica como obter um sinal estimado  $\hat{s}[n]$  quando é aplicado um filtro só-polos inverso de ordem  $p$  a um impulso discreto unitário  $\delta[n]$ . Espera-se obter na saída um sinal  $\hat{s}[n]$  que seja o mais semelhante possível ao sinal sísmico.

$$\delta[n] \rightarrow H_I(z) = \frac{1}{G} \left[ 1 - \sum_{k=1}^p a_k z^{-1} \right] \rightarrow \hat{s}[n] \quad (9)$$

Em que:

$H_I(z)$ , corresponde à função de transferência inversa do sistema,

$\delta[n]$ , refere-se ao impulso,

$\hat{s}[n]$ , é o sinal modelado e

$a_k$ , refere-se aos coeficientes do filtro.

Para isso, é suficiente ajustar os parâmetros  $a_k$  e minimizar o erro entre  $\hat{s}(n)$  (o sinal modelado) e  $s(n)$  do sinal original, conforme indicado pela Equação 10, sendo resolvido por um modelo de otimização. Também pode ser observado desde o domínio do tempo, como se indica nas Equação 11 e Equação 12.

$$e = \hat{s}[n] - s[n] \quad (10)$$

Em que:

$e$  corresponde ao erro que deve ser minimizado,

$s[n]$  é o sinal original, objetivo da análise (o sinal sísmico original).

$$g[n] = s[n] - \sum_{k=1}^p a_k s[n-k] \approx \delta[n] \quad (11)$$

Em que:

$g[n]$  é um sinal semelhante a um impulso,

$s[n-k]$  é o sinal no tempo  $n-k$ .

$$e = g[n] - \delta[n] \quad (12)$$

Com base no exposto anteriormente, seja usando a função de transferência ou analisando o sinal no domínio do tempo, o conjunto finito dos parâmetros  $a_k$  de tamanho  $p$  é capaz de representar o sinal (Oppenheim, 1999).

Para esta pesquisa, foi decido representar os sinais de sismos vulcânicos usando um conjunto de 12 características extraídas por meio da codificação de predição linear, conforme descrito nas metodologias também aplicadas em sinais de sismos vulcânicos, propostas por Titos et al. (2018a), Martínez et al. (2021). Desta forma todos os sinais ficaram representados pelo mesmo número de coeficientes.



### 4.2.3 Coeficientes Cepstrais de Frequencia Linear (LFCC)

A extração dos coeficientes LFCC, é uma técnica amplamente utilizada na representação paramétrica dos sinais de fala, e é derivada da técnica *Mel-Frequency Cepstral Coefficients* (MFCC) (Davis; Mermelstein, 1980b). Ela tem sido adotada no processamento de sinais de sismos vulcânicos, e baseia-se na variação da largura de banda para extrair características relevantes dos sinais (Rabiner; Juang, 1999).

Os coeficientes LFCC representam um conjunto de parâmetros, obtidos pela aplicação da Transformada Discreta do Coseno (DCT) nos logaritmos das energias resultantes da passagem do espectro do sinal (aplicando a Transformada de Fourier (DFT)) por um banco de filtros triangulares. Esses coeficientes têm a característica de serem descorrelacionados (Rabiner; Juang, 1999).

A DFT de um sinal discreto de entrada  $y[n]$  com  $N$  pontos é definida pela Equação 13.

$$Y(k) = \sum_{n=1}^N y(n) \cdot e^{\left(\frac{-j2\pi nk}{N}\right)} \quad (13)$$

Em que:

$Y(k)$  representa o espectro do sinal transformado,

$y[n]$  é o sinal discreto de entrada.

$N$  é a quantidade de amostras de  $y(n)$  que serão transformados, resultando na resolução das frequências no espectro (Oppenheim; Schaffer, 2004).

Com  $1 \leq k \leq N$ , é aplicado o banco de filtros espaçado linearmente no espectro obtido. A resposta do filtro  $\psi_i(k)$  do filtro  $i$  no banco de filtros é definida pela Equação 14.

$$\psi_i(k) = \begin{cases} 0 & \text{Para } k < k_{b_{i-1}} \\ \frac{k - k_{b_{i-1}}}{k_{b_i} - k_{b_{i-1}}} & \text{Para } k_{b_{i-1}} \leq k \leq k_{b_b} \\ \frac{k_{b_{i+1}} - k}{k_{b_{i+1}} - k_{b_i}} & \text{Para } k_{b_{i-1}} \leq k \leq k_{b_{i+1}} \\ 0 & \text{Para } k \leq k_{b_{i+1}} \end{cases} \quad (14)$$

Se  $Q$  denota o número de filtros no banco de filtros, então a Equação 15 define limites do filtro em:

$$\left\{ k_{b_i} \right\}_{i=0}^{Q+1} \quad (15)$$

Na próxima etapa, as energias de saída  $e(i)$  (com  $i = 1, 2, \dots, Q$ ) dos filtros passa banda são calculadas como a soma das energia do sinal  $|Y(k)|^2$  para a banda de frequência determinada para cada filtro  $\psi_i(k)$ , como indicado pela Equação 16.

$$e(i) = \sum_k^N |Y(k)|^2 \psi_i(k) \quad (16)$$

Finalmente, é aplicada a DCT ao logaritmo das energias do banco de filtros  $\{\log[e(i)]\}_{i=1}^Q$  com o propósito de decorrelacionar as energias e obter os coeficientes  $C_N$ , como indicado na Equação 17.

$$C_N = \sqrt{\frac{2}{N}} \sum_{l=0}^{(Q-1)} \log[e(l+1)] \cdot \cos \left[ n \left( \frac{2l+1}{2} \right) \frac{\pi}{Q} \right] \quad (17)$$

Em que:

$C_N$  corresponde aos coeficientes LFCC.

$m = 0, 1, 2, \dots, R-l$ , e  $R$  representa o número de coeficientes LFCC desejado.

Seguindo as metodologias propostas por Cortés et al. (2015), Martínez et al. (2021), este trabalho propõe o cálculo de 15 coeficientes cepstrais de frequência linear para representar os sinais de sismos vulcânicos, derivados da análise da magnitude dos espectros de frequência. No contexto específico dos sinais de sismos vulcânicos, a seleção de 15 coeficientes LFCC visa manter uma representação compacta e informativa das características fundamentais desses sinais, possibilitando uma análise robusta e detalhada para fins de classificação e análise sísmica.


#### 4.2.4 Autoencoder Dual de Características (DAF)

##### 4.2.4.1 Arquitetura Autoencoder

Os Autoencoders são Redes Neurais Artificiais (ANN) projetadas para gerar uma representação de menor dimensão que se denomina "espaço latente" ou "código", conforme o próprio nome sugere. Essa abordagem possibilita extrair informações relevantes dos dados originais. O novo vetor de característica é capaz de encapsular uma nova representação comprimida e abstrata, capturando de maneira eficaz as relações subjacentes e as características aprendidas que não são facilmente identificadas a olho nu. Essas representações podem auxiliar em tarefas em *machine learning*, como geração de dados, classificação, reconstrução e geração de novas amostras (Kubat, 2005; Skansi, 2018).

Essas arquiteturas foram inicialmente introduzidas por Rumelhart, Hinton e Williams (1986). É comum descrevê-las como de aprendizado auto-supervisionado, já que não requerem rotulação no conjunto de dados de treinamento. Isso se deve ao fato de que os próprios dados de entrada correspondem a saída esperada. Normalmente, as camadas ocultas têm uma dimensão menor, conforme ilustrado na Figura 16. No entanto, existem arquiteturas de autoencoders em que as camadas ocultas podem ter uma dimensão maior do que as camadas de entrada e saída, como discutido por Goodfellow, Bengio e Courville (2016), Yin et al. (2019).

Figura 16 - Esquema da arquitetura Autoencoder



Fonte: Elaborado pelo autor.

De modo matemático segundo autores como Kubat (2005), Skansi (2018), Ertel (2018), para cada amostra  $x^{(i)}$  no conjunto de dados de treinamento  $D = \{x^{(1)}, x^{(2)}, \dots, x^{(N)}\}$ , em que  $(i)$  e  $N$ , denotam o vetor de entrada da  $i$ -ésima amostra e o número de amostras, respectivamente. A camada de codificação é definida pela Equação 18.

$$f(x) = s_e(\mathbf{W}_e x + b_e) \quad (18)$$

Em que:

$\mathbf{W}_e$  corresponde à matriz de pesos,

$b_e$  é o vetor bias e,

$s_e$  é a função de ativação da camada de codificação.

De maneira semelhante a camada de decodificação é definida pela Equação 19:

$$g(x) = s_d(\mathbf{W}_d x + b_d) \quad (19)$$

Portanto, a saída do Autoencoder é definida pela composição das funções  $g$  e  $f$  conforme mostra a Equação 20.

$$y = g(f(x)) \quad (20)$$

O objetivo do Autoencoder é aprender uma representação das características mais significativas na camada de codificação, de modo a permitir a reconstrução das entradas. Portanto, o problema de aprendizado do Autoencoder é encontrar um conjunto de parâmetros  $\theta = \mathbf{W}_e, b_e, \mathbf{W}_d, b_d$ , que minimiza o erro de reconstrução entre as entradas e as saídas do Autoencoder. Desta forma a definição formal é  $f: \mathbb{R}^n \rightarrow \mathbb{R}^p$  (codificador) e  $g: \mathbb{R}^p \rightarrow \mathbb{R}^n$  (decodificador), satisfazendo a Equação 21.

$$\arg \min_{\theta} \sum_{i=1}^N L\left(x^{(i)}, g(f(x))\right) \quad (21)$$

Em que:

$$L(x, y) = \|y - x\|_2 \quad (22)$$

Com o objetivo de evitar o *overfitting*, a regularização de decaimento de peso  $l_2$  proposta por Krogh e Hertz (1991), Hinton (2010), é adicionada para restringir as magnitudes dos pesos. Assim, o problema de otimização é limitado pela Equação 23. Além disso, é comum adicionar o método *Dropout* (Srivastava et al., 2014) em camadas com um maior número de neurônios para evitar o *overfitting*.

$$\arg \min_{\theta} \sum_{i=1}^N L\left(x^{(i)}, g(f(x))\right) + \frac{1}{2} \lambda \|\mathbf{W}\|_2 \quad (23)$$

Em que:

$\lambda$  denota o parâmetro de regularização,

$\mathbf{W}$  corresponde à matriz de pesos que contém as matrizes  $\mathbf{W}_e$  y  $\mathbf{W}_d$ .

Normalmente, o parâmetro  $\theta$  é otimizado utilizando o algoritmo de retropropagação, similar ao de uma ANN multicamada convencional. No entanto, no caso de Autoencoder, as saídas são definidas para serem iguais às entradas, ao contrário de uma rede neural tradicional.

Em relação às funções de ativação, é interessante mencionar que o uso de uma função linear em um Autoencoder (não empilhado) com um número de neurônios ocultos  $M$  menor que o número de neurônios da entrada  $n$ , reduz o problema ao contexto da Análise de Componentes Principais (PCA) (Bengio et al., 2009). Isso ocorre porque a função linear mantém a relação linear entre as entradas e as saídas, sem adicionar complexidade ao espaço latente.

O comportamento do Autoencoder também pode ser afetado pelo tamanho das camadas ocultas. Quando  $M < n$ , o Autoencoder realiza uma redução de características, processo semelhante ao PCA. Por outro lado, quando  $M > n$  o Autoencoder tende a aprender uma função de identidade. Nesse sentido, na prática o Autoencoder explora regularidades estatísticas nos dados para aprender recursos úteis (Bengio et al., 2009), razão pela qual, na redução dimensional  $M$  é tipicamente escolhido como menor que  $n$  para obter esse efeito.

Em um Autoencoder de camada única, a capacidade de representação pode ser limitada (Bengio et al., 2009; Bengio; Courville; Vincent, 2013). Para aumentar a capacidade de representação e aprender características mais relevantes e abstratas a partir dos dados de entrada, é comum utilizar arquiteturas mais complexas e profundas, como os Autoencoders empilhados (Ng et al., 2016). Esses Autoencoders consistem na sobreposição de vários Autoencoders, em

que as saídas da camada de codificação de um Autoencoder são usadas como entradas para o próximo (Vincent et al., 2010). Neste sentido, é importante mencionar que somente o primeiro Autoencoder utiliza os dados originais como entrada.


#### 4.2.4.2 Autoencoder Dual de Características como técnica de caracterização

O Autoencoder DAF combina as características aprendidas por dois Autoencoders empilhados que usam funções de ativação sigmoide *sigmoid* e tangente hiperbólica *tanh* (Ng et al., 2016). Para este trabalho de pesquisa, o DAF utiliza Autoencoders empilhados para aprender as características dos sinais sismo-vulcânicos. Enquanto um único autoencoder empilhado pode não ser suficientemente robusto para capturar características úteis (Bengio; Courville; Vincent, 2013; Bengio; Delalleau, 2011; Baldi, 2012), múltiplos autoencoders empilhados podem fornecer uma representação mais rica, embora isso possa aumentar significativamente o custo computacional durante o treinamento.


O DAF consiste em duas estruturas de autoencoders empilhados, cada uma treinada de forma independente com uma função de ativação específica. A Figura 17 apresenta o esquema geral do DAF. Durante a etapa de aprendizado, o primeiro autoencoder recebe os dados originais dos sinais sísmicos e produz um espaço latente. Em seguida, esse espaço latente é empregado como entrada para o segundo autoencoder, que gera um novo espaço latente baseado nessa informação.

Após obter os espaços latentes do segundo autoencoder empilhado em cada estrutura, cada um correspondendo a uma função de ativação específica, os dois espaços latentes são concatenados para representar os sinais. Esse processo de codificação de características resulta na fusão dos espaços latentes, capturando informações provenientes de duas funções de ativação diferentes, fornecendo, assim, uma representação abrangente dos sinais sísmicos.

Figura 17 - Esquema da arquitetura Autoencoder Dual de Características (DAF)




(a) Fase de aprendizado de características



(b) Fase de codificação das características

Fonte: Elaborado pelo autor.

Autoencoders com diferentes funções de ativação produzem respostas distintas, resultando na aprendizagem de características diferentes e, conseqüentemente, gerando representações mais robustas, dentre as funções de ativação existente, a *sigmoid* e tangente hiperbólica (*tanh*) são as mais utilizadas em ANN. As respostas de ativação e suas respectivas derivadas na faixa de  $[0, 1]$  podem ser observadas na Figura 18. As funções de ativação *sigmoid* e *tanh* e as respectivas derivadas são definidas Equação 24, Equação 25, Equação 26 e Equação 27.

Figura 18 - Respostas de ativação e derivada das funções *sigmoid* e *tanh*

(a) Resposta às entradas na faixa [0, 1]

(b) Derivada das funções às entradas

Fonte: Elaborado pelo autor

$$sigmoid'(x) = \frac{1}{1 + e^{-x}} \quad (24)$$

$$tanh'(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (25)$$

$$sigmoid'(x) = \frac{e^{-x}}{(1 + e^{-x})^2} \quad (26)$$

$$tanh'(x) = \frac{4}{(e^{2x} + e^{-2x})} \quad (27)$$

Na Figura 18 é possível notar que a função *tanh* é mais sensível às mudanças nas entradas, gerando derivadas maiores e possuindo uma faixa de valores de ativação mais ampla em comparação com a função *sigmoid*. Além disso, na mesma figura, pode-se observar que a função *tanh* varia sempre que uma pequena alteração ocorre nas entradas, o que permite capturar informações mais detalhadas para representar os sinais sismo-vulcânicos.

Em contraste, um classificador com baixa sensibilidade produz maior robustez ao ignorar mudanças detalhadas nas entradas (Yeung et al., 2015). Neste contexto, a função *sigmoid* fornece uma representação mais global dos dados. Desta forma, torna-se possível explorar tanto as informações detalhadas localmente quanto representações globais para auxiliar o processo de classificação dos sinais de sismos vulcânicos.

Para esta pesquisa adotou-se as seguintes dimensões para a arquitetura do Autoencoder DAF:

- O **primeiro autoencoder** que recebe os sinais de sismos vulcânicos originais tem as dimensões: 3000 x 2000 x 1000 x 800 x 1000 x 2000 x 3000, sendo as camadas de

entrada e saída com 3000 neurônios, enquanto a camada oculta responsável por gerar o espaço latente é composta por 800 neurônios. Isto quando o Autoencoder DAF recebe os sinais sísmicos no domínio do tempo.

- Continuando com os sinais no domínio do tempo, o **autoencoder empilhado** na estrutura DAF que recebe o espaço latente, gerado pelo primeiro autoencoder, como informação de entrada tem as seguintes dimensões: 800 x 600 x 400 x 200 x 400 x 600 x 800, tendo as camadas de entrada e saída 800 neurônios, conforme a dimensão do espaço latente do primeiro autoencoder, já o espaço latente deste autoencoder foi definido com 200 neurônios.
- Ao lidar com os dados no domínio da frequência, as dimensões do **primeiro autoencoder** foi: 1500 x 1000 x 500 x 400 x 500 x 1000 x 1500, de igual forma, sendo as camadas de entrada e saída com 1500 neurônios e o espaço latente gerado na camada oculta com 400 neurônios.
- As seguintes dimensões foram utilizadas pelo **autoencoder empilhado**: 400 x 300 x 200 x 100 x 200 x 300 x 400. Sendo 400 a quantidade de neurônios nas camadas de entrada e saída que recebem e reconstroem o espaço latente gerado pelo primeiro autoencoder. O espaço latente gerado neste segundo autoencoder contém 100 neurônios.

Com os sinais no domínio do tempo, cada estrutura de Autoencoder DAF gera um espaço latente com 200 elementos, resultante do processo utilizando tanto a função de ativação *sigmoid* quanto a função de ativação *tanh*. Assim, a concatenação de ambos gera um novo vetor de representação com as 400 características mais relevantes dos sinais. De maneira similar, foram obtidos dois espaços latentes, cada um com 100 elementos (obtido com função de ativação diferente), para formar um vetor que representa os sinais no domínio da frequência, resultando em 200 características.

As dimensões das camadas na estrutura proposta DAF desempenham um papel crítico na complexidade do modelo, influenciando diretamente a quantidade de parâmetros a serem treinados. As matrizes de pesos associadas a cada camada geram alta dimensionalidade, o que pode resultar em condições de sobreajuste (*overfitting*) durante o treinamento do modelo.

Na estrutura do DAF, ao considerar os sinais no domínio do tempo o primeiro autoencoder requer o treinamento de 17.609.800 parâmetros, enquanto o segundo autoencoder necessita treinar 1.603,000 parâmetros. Por outro lado, ao tratar os sinais no domínio da frequência, o primeiro autoencoder requer o treinamento de 4.404.900 parâmetros, já o segundo de 401.500 parâmetros.



Essa considerável quantidade de parâmetros destaca a importância de mitigar o risco de sobreajuste. Por isso, a aplicação de técnicas de regularização como  $l_2$  e *Dropout* se tornam essenciais para controlar a complexidade do modelo. Foram testados quatro valores de Dropout e quatro para a regularização  $l_2$ , usando a estratégia *GridSearch*. Esta estratégia permite identificar os valores ótimos para os hiperparâmetros ao provar sistematicamente cada opção, selecionando a combinação que proporciona o melhor desempenho no modelo. A Tabela 6 apresenta os parâmetros que foram testados para obter o melhor resultado utilizando o DAF.

Tabela 6 - Seleção de hiperparâmetros ótimos para o DAF

| Domínio    | Função ativação | Autoencoder | Dropout | Reg. L2 |
|------------|-----------------|-------------|---------|---------|
| Tempo      | <i>Sigmoid</i>  | 1           | 0.5     | 0.0001  |
|            |                 | 2           | 0.1     | 0.0003  |
|            | <i>Tanh</i>     | 1           | 0.25    | 0.0007  |
|            |                 | 2           | 0.25    | 0.0007  |
| Frequência | <i>Sigmoid</i>  | 1           | 0.1     | 0.0005  |
|            |                 | 2           | 0.1     | 0.0002  |
|            | <i>Tanh</i>     | 1           | 0.35    | 0.0007  |
|            |                 | 2           | 0.35    | 0.0007  |

### 4.3 Modelo de classificação

O modelo de classificação empregado nesta pesquisa foi uma rede neural do tipo *Multi Layer Perceptron* (MLP). A arquitetura geral do modelo para testar as diferentes técnicas de caracterização consistiu em 3 camadas: a camada de entrada, cujo tamanho varia de acordo com a técnica de caracterização, uma vez que cada representação consiste em um vetor de tamanho diferente; a camada oculta; e a camada de saída. As dimensões destas duas últimas camadas foram mantidas constantes, visando manter o modelo o mais padronizado possível.

Para conseguir a melhor combinação de hiperparâmetros, como a escolha da função de ativação e determinar a quantidade de neurônios na camada oculta, utilizou-se a técnica *GridSearch*. O objetivo foi otimizar o desempenho do modelo por meio da seleção da melhor combinação de hiperparâmetros. Os resultados revelaram que a função de ativação *relu* e a utilização de 20 neurônios na cada oculta proporcionaram o melhor desempenho ao testar o modelo com diferentes vetores de caracterização dos sinais como dados de entrada.

Para cada conjunto de dados resultante das técnicas de caracterização (PCA, LPC, LFCC e DAF), o classificador é treinado de forma independente. A arquitetura MLP adotada possui a seguinte configuração: a camada de entrada varia de acordo com o vetor de caracterização dos sinais, a camada oculta conta com 20 neurônios e a camada de saída possui 3 neurônios.

Tabela 7 - Resumo dos hiperparâmetros no classificador MLP

| Camada                        | LPC                             | LFCC | PCA  | DAF       | Função ativação |
|-------------------------------|---------------------------------|------|------|-----------|-----------------|
| <b>Dimensão</b>               |                                 |      |      |           |                 |
| Entrada                       | 12                              | 15   | 35*  | 400/200** | relu            |
| Oculto                        | 20                              | 20   | 20   | 20        | relu            |
| Saída                         | 3                               | 3    | 3    | 3         | softmax         |
| <b>Parâmetros a treinar</b>   |                                 |      |      |           |                 |
|                               | 323                             | 383  | 1283 | 8083      |                 |
| <b>Outros hiperparâmetros</b> |                                 |      |      |           |                 |
| Função de perda               | <i>Categorical crossentropy</i> |      |      |           |                 |
| Otimizador                    | <i>adam</i>                     |      |      |           |                 |
| Epocas                        | 25                              |      |      |           |                 |
| Tamanho do lote               | 16                              |      |      |           |                 |

Nota: \* Quantidade de componentes principais tanto no domínio do tempo como na frequência.

\*\* 400 características no domínio de tempo, e 200 características no domínio da frequência.

Este modelo de classificação requer o treinamento de 8083 parâmetros (para 400 neurônios na camada de entrada, que é a dimensão do vetor de caracterização), sem a aplicação de técnicas de regularização para controle de sobreajuste durante o treinamento. A Tabela 7 fornece um resumo da informação sobre os hiperparâmetros escolhidos para o modelo classificador MLP.

#### 4.4 Configuração Experimental


Para este estudo, foram exploradas duas abordagens distintas na análise dos dados sísmicos: uma considerando os sinais no domínio do tempo e outra no domínio da frequência. Foram aplicadas técnicas específicas de caracterização, e que o método LPC foi empregado nos sinais no domínio do tempo devido à sua relevância nesse contexto, enquanto o método LFCC foi utilizado para analisar os sinais no domínio da frequência.

A condução dos experimentos foi realizada considerando uma divisão estratégica do banco de dados. Os registros do vulcão Galeras, que incluem as classes VT, LP e TOR, foram divididas em conjuntos de treinamento (60%), validação (20%) e teste (20%). Os conjuntos de treinamento e validação foram usados para treinar os modelos de Autoencoder e classificação. Entretanto, 100% dos dados registrados nos vulcões Etna (classe VT) e Vulcano (classe LP) (dados da Itália) foram reservados exclusivamente para o conjunto de teste. Esses dados, combinados com o subconjunto de teste dos dados de Galeras, foram utilizados para avaliar os modelos Autoencoder e classificador.

Com relação às técnicas LPC, LFCC e PCA, estas foram aplicadas a todos os dados do vulcão Galeras e os da Itália. Após a obtenção das representações das características dos sinais, os dados caracterizados do Galeras foram divididos em conjuntos de treinamento (60%), validação (20%) e teste (20%). Por outro lado, todos os dados caracterizados da Itália foram destinados

ao conjunto de teste. A Figura 19 fornece uma ilustração visual da configuração experimental utilizada.

Figura 19 - Configuração experimental



Fonte: Elaborado pelo autor.

## 4.5 Métricas de Avaliação

Esta etapa permite uma avaliação objetiva do impacto das técnicas de caracterização utilizadas no desempenho do modelo classificador. A seleção das métricas de avaliação foi realizada com o objetivo de determinar a capacidade preditiva do modelo, incluindo métricas clássicas como precisão, sensibilidade e F1-Score. Além disso, foram empregadas a curva *Receiver Operating Characteristic* (ROC) para calcular a Área sob a Curva (AUC), e a curva *precision-recall*, visando obter uma representação gráfica da capacidade de discriminação do modelo.

As métricas de avaliação, bem como as curvas, são frequentemente empregadas em problemas de classificação binária. Neste trabalho de pesquisa, foi adotada a adaptação *one vs o rest*, que consiste na decomposição do problema multi classe em vários problemas binários. Essa abordagem possibilita a interpretação dos resultados, permitindo uma análise mais detalhada do desempenho do modelo.

Para esta análise inclui-se a matriz de confusão, a qual fornece uma interpretação estrutu-

rada dos resultados de classificação, fundamental para o cálculo das métricas, já que permite identificar os verdadeiro positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN), os quais são definidos como:

- VP: Representa a correta previsão da classe positiva.
- VN: Representa a correta previsão da classe negativa.
- FP: Refere-se à predição errada, em que o modelo erroneamente previu uma classe como sendo a classe positiva.
- FN: Refere-se à previsão errada, quando o modelo classifica como negativa à classe positiva.

É importante destacar que as métricas são calculadas considerando um problema binário, as mesmas métricas são utilizadas ao lidar com um problema multi-classe, considerando a estratégia de comparação de uma classe com o resto (one vs rest – OvsR). A seguir, apresenta-se o cálculo de cada das métricas:

- Sensibilidade ( $Se$ ): Também conhecida como a taxa de verdadeiros positivos ou *recall*, permite identificar a proporção dos dados que foram corretamente identificados como positivos (Parikh et al., 2008).

$$\frac{VP}{VP + FN} \quad (28)$$

- Precisão ( $Esp$ ): Representam a capacidade do modelo para classificar corretamente os casos positivos entre todos os casos que predice como positivos.

$$\frac{VP}{VP + FP} \quad (29)$$

- F1-score: É a média harmônica entre as métricas precisão e sensibilidade, com valores no intervalo de 0 a 1, sendo 1 o desempenho ótimo. Essa métrica penaliza os erros, pois o valor desta métrica é alto quando tanto a precisão quanto a sensibilidade forem altas (Yacoub; Axman, 2020).

$$\frac{VP}{VP + \frac{1}{2}(FP + FN)} \quad (30)$$

A curva ROC é um estimador estatístico que oferece uma representação gráfica da performance do modelo para diferentes limiares de classificação extraídos do modelo. Traça no eixo

das ordenadas a taxa de verdadeiros positivos e a taxa de falsos positivos nas abscisas (Fawcett, 2006). A AUC da curva ROC é uma medida que resume o comportamento do modelo em um único valor que pode ser interpretado conforme se indica na Tabela 8.

Tabela 8 - Interpretação dos valores AUC na curva ROC

| Intervalo | Resultado | Intervalo | Resultado |
|-----------|-----------|-----------|-----------|
| 0.5 - 0.6 | Ruim      | 0.7 - 0.8 | Aceitável |
| 0.8 - 0.9 | Bom       | > 0.9     | Ótimo     |

Por outro lado, a curva *precision-recall*, é apropriada com conjuntos de dados desbalanceados devido à sua sensibilidade à classe minoritária. Esta métrica considera tanto os falsos positivos quanto os verdadeiros positivos, avaliando, assim, o equilíbrio entre eles, em contraste com o foco exclusivo nos verdadeiros positivos. Essa curva ilustra a relação entre a precisão e a sensibilidade ao variar o limiar de classificação. Uma área maior sob a curva *precision-recall* indica um melhor desempenho.

## **5 RESULTADOS**

Neste capítulo, são apresentados os resultados obtidos neste trabalho de pesquisa. Inicialmente, serão discutidos os resultados da caracterização dos sinais vulcânicos, lembrando que as técnicas de caracterização transformam o sinal de entrada em um vetor de características que idealmente fornece a informação discriminativa ao modelo classificador. Durante a fase de discussão das caracterizações obtidas, pretende-se analisar as discrepâncias entre as diferentes representações adquiridas com cada técnica de caracterização utilizada.

Em seguida, são expostos os resultados da validação cruzada no treinamento do modelo classificador MLP, abordando os sinais no domínio do tempo e da frequência. Este ponto visa discutir como o domínio dos dados influencia o desempenho do treinamento do modelo. Vale ressaltar que o treinamento foi realizado exclusivamente com os sinais registrados no vulcão Galeras unicamente.


Finalmente, são detalhados os resultados da classificação usando o conjunto de validação para os sinais do vulcão Galeras. Isso permite avaliar o comportamento do modelo ao lidar com dados completamente novos, mas do mesmo contexto vulcânico em que o modelo foi treinado. Além disso, é descrito outro experimento incluindo dados com sinais de dois vulcões da Itália como parte do conjunto de validação, a fim de compreender como o modelo se comporta diante de dados provenientes de vulcões diferentes.

### **5.1 Resultados da caracterização**

#### **5.1.1 Caracterização dos sinais usando a técnica LPC**

Conforme mencionado na metodologia, esta técnica gerou um vetor com 12 componentes, sendo uma representação bastante compacta dos sinais. A Figura 23 apresenta um gráfico que destaca as características que melhor representam cada sinal, exibindo 10 sinais do banco de dados escolhidos de forma aleatória de cada classe. Além disso, mostra a caracterização dos sinais do vulcão Etna e Volcano, que fazem parte das classes VT e LP, respetivamente.

Figura 20 - Coeficientes LPC dos sinais no domínio do tempo




Fonte: Elaborado pelo autor.

Como é possível observar, a representação para a classe VT do Galeras mostrou uma notável homogeneidade, em que 10 sinais aleatórios parecem manter uma grande similaridade nas características intrínsecas extraídas. Por outro lado, analisando os sinais representados pelos coeficientes LPC para os sinais LP e TOR do Galeras é possível identificar uma menor homogeneidade nas características intrínsecas em cada classe, embora manteve um padrão no formato para cada uma destas classes.

Ao analisar a caracterização dos sinais VT do Etna, observa-se um padrão definido no formato produzido pelos coeficientes, porém mostrando menos homogeneidade. Para a caracterização dos sinais LP do Volcano, a similaridade entre as características intrínsecas é menor, demonstrando menor similaridade no formato construído pelos coeficientes LPC. Também é importante ressaltar que, embora os sinais do vulcão Etna correspondam à classe VT, há bastante diferença no formato que representa esta mesma classe em Galeras, o que também ocorre na representação LP para Galeras e Volcano.

A matriz de correlação por classe, pode ser vista na Figura 21, mostra as similaridades que cada classe apresenta em relação às outras. Pode-se observar que as classes VT, LP e TOR do vulcão Galeras apresentam uma relação forte e estreita entre si, excluindo os dados VT do Etna y LP do Volcano. A matriz revela a inexistência de uma relação entre a classe VT do Galeras e a classe VT do Etna, apresentando uma correlação de apenas 0,097. Por outro lado, a relação entre a classe LP do Galeras e a classe LP do Volcano é fraca, apresentando 0,53 de correlação entre elas. Além disso, a classe LP do Volcano possui uma correlação semelhante com as classes VT e Tor do Galeras.


Figura 21 - Correlação por classe para a caracterização LPC



Fonte: Elaborado pelo autor.

Para avaliar a separabilidade entre as classes após a caracterização, realizou-se uma análise de discriminante linear, conforme mostrado na Figura 22. Observam-se *clusters* definidos para as classes, mas uma baixa separação entre elas, já que todas estão concentradas na faixa (-5, 5). Nota-se uma sobreposição entre as classes LP do Galeras e LP do Volcano. No entanto, a classe LP do Volcano apresenta alguns dados distribuídos nas classes TOR e VT do Etna.

Figura 22 - Análise de Discriminante Linear para a caracterização LPC




Fonte: Elaborado pelo autor.



### 5.1.2 Caracterização dos sinais usando a técnica LFCC

Esta técnica de caracterização gerou um vetor com 15 componentes. Assim como a técnica LPC, trata-se de uma representação bastante compacta dos sinais. A Figura 23 exibe os formatos construídos pelas características que melhor representam cada sinal.


Figura 23 - Caracterização dos sinais usando a técnica LFCC



Fonte: Elaborado pelo autor.

Os resultados das representações obtidas pela técnica LFCC para cada classe apresentam formatos bastante homogêneos, evidenciando a capacidade dessa técnica para extrair padrões comuns que melhor caracterizam cada classe. Além disso, observa-se uma distinção clara entre os formatos das classes VT, LP e TOR. A classe VT do Galeras apresenta um formato bastante similar com a classe VT do Etna, revelando que ambos sinais compartilham características que os representam. Por outro lado, isso não acontece entre as classe LP do Galeras e a classe LP do Volcano.

Figura 24 - Correlação por classe para a caracterização LFCC




Fonte: Elaborado pelo autor.

A Figura 24 apresenta a matriz de correlação por classe, analisando-a nota-se que a representação utilizando a técnica LFCC estabelece uma forte relação entre as classes VT, LP e TOR do Galeras com a classe VT do Etna. No entanto, essa relação é mais acentuada com a classe TOR do que com a classe VT. Por outro lado, a classe LP do Volcano não demonstra uma relação com as demais classes, especialmente com a classe LP do Galeras.

A separação entre as classes após aplicar a técnica LFCC, pode ser visualizada na Figura 25. A análise de discriminante linear revelou que as classes formam *clusters*, porém há sobreposição evidente entre elas. Especificamente, a classe VT mostra uma dispersão em alguns dos seus dados.

Figura 25 - Análise de Discriminante Linear para a caracterização LFCC




Fonte: Elaborado pelo autor.


### 5.1.3 Caracterização dos sinais usando a técnica PCA

Esta técnica foi aplicada aos sinais nos domínios do tempo e da frequência, resultando em um vetor com 35 componentes em ambos casos. As características para cada classe no domínio do tempo são apresentados na Figura 26 (a). É possível observar que, para os 10 sinais aleatórios plotados por classe, há um formato definido, indicando uma homogeneidade entre as características extraídas em cada classe para os sinais no domínio do tempo. O mesmo comportamento foi evidenciado nos sinais no domínio da frequência, embora com uma menor homogeneidade, conforme demonstrado na Figura 26 (b).

Figura 26 - Caracterização dos sinais usando a técnica PCA



(a) Caracterização PCA no domínio de tempo




(b) Caracterização PCA no domínio da frequência

Fonte: Elaborado pelo autor.

A relação entre as classes após a aplicação da técnica PCA no domínio do tempo é ilustrada na Figura 27 (a). Observa-se uma relação forte entre as classes, independentemente do seu contexto vulcânico, exceto da classe VT do Galeras que não tem correlação com as demais classes, inclusive com a classe VT do Etna. Os resultados das relações entre as classes no domínio da frequência são apresentados na Figura 27 (b). A correlação entre as classes apresentam o mesmo comportamento, porém com uma relação menor entre elas.

Figura 27 - Correlação por classe para a caracterização PCA




(a) Correlação por classe no domínio de tempo

(b) Correlação por classes no domínio da frequência

Fonte: Elaborado pelo autor.

Ao aplicar a análise discriminante linear, tanto no domínio do tempo quanto da frequência, observou-se uma distribuição entre as classes com uma maior densidade no domínio do tempo, como evidenciado na Figura 28 (a). Sugerindo uma boa separação entre as classes. No domínio da frequência, como é evidenciado na Figura 28 (b) a distribuição entre as classes apresenta sobreposição e maior dispersão entre as classes.

Figura 28 - Análise de Discriminante Linear para a caracterização PCA



(a) Análise LDA no domínio do tempo


(b) Análise LDA no domínio da frequência

Fonte: Elaborado pelo autor.


### 5.1.4 Caracterização dos sinais usando a técnica DAF

Esta técnica gerou um vetor com 400 componentes no domínio do tempo e 200 componentes no domínio da frequência. A Figura 29 apresenta um gráfico que destaca as características que melhor representam cada sinal, exibindo 10 sinais aleatórios por cada classe.

Figura 29 - Caracterização dos sinais usando a técnica DAF



(a) Caracterização DAF no domínio de tempo



(b) Caracterização DAF no domínio da frequência


Fonte: Elaborado pelo autor.

No domínio do tempo, nota-se que o DAF é capaz de extrair características comuns em cada uma das classes, destacando-se a homogeneidade nos formatos das classes VT, LP e TOR do Galeras. Além disso, cada uma delas apresenta distinção uma da outra, o que facilita a representação de cada classe. Porém, para as classes VT do Etna e LP do Volcano, observou-se um comportamento distinto, já que os formatos das características não demonstraram uniformidade, indicando que não foi possível extrair características comuns que representem cada uma dessas classes.

Contudo, no domínio da frequência, a técnica demonstrou a capacidade de extrair características comuns para todas as classes, identificado nos formatos homogêneos na maioria delas, exceto na classe LP do Galeras. No entanto, não foi possível identificar uma representação distinta para cada classe.

A análise de correlação entre as classes pode ser observada nas matrizes da Figura 30, que indica a relação entre as classes quando os sinais foram abordados no domínio do tempo, e no domínio de frequência.

Figura 30 - Correlação por classe para a caracterização DAF



(a) Correlação por classe no domínio de tempo (b) Correlação por classes no domínio da frequência


Fonte: Elaborado pelo autor.

A análise da matriz de correlação no domínio do tempo revelou as relações entre as classes. Observa-se uma forte relação entre as classes VT do Etna e LP do Volcano, assim como entre elas e a classe LP do Galeras. Por outro lado, a classe VT do Galeras mostra uma relação fraca com as classes VT do Etna e LP do Volcano, enquanto a classe TOR não apresenta relação com nenhuma das classes.

No domínio da frequência, destaca-se um comportamento que indica uma correlação forte entre as classes analisadas entre si. Isto pode ser o resultado de uma informação redundante nas características extraídas usando a técnica DAF nos espectros dos sinais, obtendo características que são linearmente dependentes entre elas.

A separação entre as classes após ter aplicado a técnica DAF pode ser identificado com a análise de discriminante linear, apresentada na Figura 31.

Figura 31 - Análise de Discriminante Linear para a caracterização DAF



(a) Análise LDA no domínio do tempo

(b) Análise LDA no domínio da frequência

Fonte: Elaborado pelo autor.

No domínio do tempo, nota-se uma clara separação entre as classes, cada uma delas exibindo uma distribuição densa e distintiva. Na Figura 31 (a), observa-se a classe VT de Galeras e Etna separadas e localizadas em extremos opostos. Entretanto, há uma sobreposição entre as classes LP do Volcano e TOR do Galeras.

A análise de discriminante linear dos dados no domínio da frequência mostra uma distribuição de todas as classes em uma região, indicando sobreposição entre elas, consequentemente, uma baixa separação. Notavelmente, a classe TOR apresenta a maior dispersão nessa análise.

## 5.2 Resultados de Classificação

A seguir, serão apresentados os resultados obtido pelo processo de classificação após a etapa de caracterização. Inicialmente, serão discutidos os resultados no domínio do tempo, seguidos pela análise dos resultados no domínio da frequência.


### 5.2.1 Classificação dos dados no domínio do tempo

#### 5.2.1.1 Validação Cruzada Estratificada

O treinamento do modelo foi realizado utilizando o método de validação cruzada *k-fold*. Conforme mencionado na metodologia optou-se pelo método estratificado, devido ao desbalanceamento das classes nos sinais do vulcão Galeras. A Figura 32 ilustra o desempenho da validação cruzada por meio da análise da curva ROC para cada uma das abordagens de caracterização empregadas nos sinais de sísmicos.




Figura 32 - Validação Cruzada Estratificada no modelo de classificação



(a) Resultados da validação cruzada nos sinais caracterizadas por LPC

(b) Resultados da validação cruzada nos sinais caracterizadas por PCA



(c) Resultados da validação cruzada nos sinais caracterizadas por DAF


Fonte: Elaborado pelo autor.

O desempenho após aplicar a validação cruzada, conforme evidenciado pelas curvas ROC, demonstrou um alto rendimento ao utilizar as técnicas LPC, PCA e DAF, obtendo valores de AUC de 0,99 em todas as classes.

#### 5.2.1.1.1 Validação interna para dados caracterizados com LPC

Os resultados da validação interna usando o conjunto de validação com sinais caracterizados com a técnica LPC apontam que o modelo de classificação consegue identificar corretamente cada uma das classes, como pode ser identificado na Figura 33. É notável que a área abaixo da curva (AUC) para cada uma das classes é de 1,0, demonstrando assim que esta técnica contribui no processo de classificação para acertar nas predições dos sinais.


Figura 33 - Curva ROC para a validação interna de sinais aplicando LPC



Fonte: Elaborado pelo autor.

A curva *Precision-Recall* também foi analisada para avaliar esse processo de validação. A Figura 34 ilustra os resultados obtidos. Na curva, é possível identificar que o modelo consegue realizar previsões precisas para cada uma das classes dos sinais, reforçando assim que a técnica é adequada para a classificações dos sinais sísmicos.

Figura 34 - Curva Precision-Recall para a validação interna de sinais aplicando LPC




Fonte: Elaborado pelo autor.

#### 5.2.1.1.2 Validação interna para dados caracterizados com PCA

Os resultados da validação interna para os sinais usando a técnica PCA são mostrados na Figura 35. É possível observar um bom desempenho de classificação para todas as classes, com um AUC de 0,99. Evidenciando que a técnica PCA permite uma caracterização adequada dos sinais no domínio do tempo.


Figura 35 - Curva ROC para a validação interna de sinais aplicando PCA



Fonte: Elaborado pelo autor.

A análise da curva *Precision-Recall* pode ser observada na Figura 36. Essa curva confirma que o modelo consegue bons resultados na classificação dos sinais, com um área abaixo da curva de 0,99.

Figura 36 - Curva Precision-Recall para a validação interna de sinais aplicando PCA




Fonte: Elaborado pelo autor.

### 5.2.1.1.3 Validação interna para dados caracterizados com o DAF

A curva ROC para esse experimento pode ser observada na Figura 37. Essa curva indica resultados ótimos de classificação para todas as classes, mostrando assim que a técnica DAF contribui com a classificação dos sinais sísmicos.


Figura 37 - Curva ROC para a validação interna de sinais aplicando DAF



Fonte: Elaborado pelo autor.

A curva *Precision-Recall* também indica resultados satisfatórios na classificação dos sinais, conforme mostrado na Figura 38. A classe VT alcançou um área abaixo a curva de 1,00. Um desempenho semelhante é observado na classificação para a classe LP, com um área abaixo da curva de 0,99. Por fim, para a classe TOR é obtido um área abaixo a curva de 0,96. Isso evidencia que a técnica DAF permite previsões precisas do modelo para todas as classes, mesmo considerando o desbalanceamento entre elas.

Figura 38 - Curva Precision-Recall para a validação interna de sinais aplicando DAF



Fonte: Elaborado pelo autor.


### 5.2.1.2 Validação externa

A avaliação do desempenho e da capacidade preditiva do modelo foi realizada por meio de validação externa. Foram utilizados dados independentes dos que foram utilizados no treinamento, provenientes do vulcão Galeras além de dados do vulcão Etna (classe VT) e do vulcão Volcano (classe LP). O objetivo foi observar o potencial de generalização do modelo, principalmente para dados originados em vulcões diferentes.

#### 5.2.1.2.1 Validação externa para dados caracterizados com LPC

A matriz de confusão gerada na validação externa do modelo apresentada na Figura 39, evidenciando que o modelo não é capaz de identificar as classes corretamente.

Figura 39 - Matriz de confusão obtida após a classificação de sinais aplicando LPC



Fonte: Elaborado pelo autor.

O relatório das métricas de avaliação, apresentado na Tabela 9 oferece uma análise objetiva do desempenho do modelo na sua capacidade de generalização. O modelo demonstrou uma taxa de precisão de 40% para a classe VT, indicando que o modelo acertou essa porcentagem nas predições feitas para essa classe. No entanto, sua sensibilidade foi de apenas 13%, o que significa que somente essa porcentagem do total de sinais VT foi corretamente identificada pelo modelo. Esses resultados geram um f1-score de somente 19%, mostrando um desempenho inferior do modelo na identificação da classe VT.

Para a classe LP, o modelo apresentou uma precisão de 85%, sugerindo que o modelo frequentemente acerta quando prevê que um sinal pertence à classe LP. Porém, a sensibilidade, de apenas 1%, indica que somente uma pequena porcentagem dos sinais LP foi corretamente identificada. Isso se reflete em um baixo f1-score de 1%, mostrando que o modelo tem grande dificuldade em identificar efetivamente a classe LP. Quanto à classe TOR, é importante notar que


o modelo erra ao assumir outros sinais como se fossem da classe TOR, obtendo uma precisão de 0%, embora a sensibilidade seja de 71%, revelando a limitação significativa que o modelo tem em reconhecer esse tipo de sinais.

Tabela 9 - Relatório de métricas na classificação de sinais aplicando LPC


| Classe | Precisão | Sensibilidade | f1-score |
|--------|----------|---------------|----------|
| VT     | 0,40     | 0,13          | 0,19     |
| LP     | 0,85     | 0,01          | 0,01     |
| TOR    | 0,0      | 0,71          | 0,0      |

A curva ROC - macro mostra que a capacidade de generalização do modelo é limitada quando lida com novos dados, como pode ser observado na Figura 40 (a). Foi obtido um valor AUC de 0,35, demonstrando que o modelo tem dificuldades para discriminar corretamente entre as classes. A Figura 40 (b) permite a análise da curva ROC para cada uma das classes, sendo a classe VT a que apresenta maior dificuldade em ser identificada, com um AUC de 0,09, seguida da classe TOR com AUC de 0,29. Por fim, a classe LP apresentou o maior valor, porém insatisfatório, com AUC de 0,67.

Figura 40 - Curva ROC na classificação de sinais aplicando LPC



(a) Curva ROC macro



(b) Curva ROC por classes


Fonte: Elaborado pelo autor.

Também foi analisada a curva *Precision-Recall*, conforme visualizado na Figura 41, ela oferece detalhes objetivos sobre o desempenho do modelo na classificação. Para a classe VT, foi registrada uma área abaixo da curva de 0,64, evidenciando uma limitação na precisão do modelo ao identificar corretamente essa classe, apesar de ser a classe majoritária no conjunto de validação.

Enquanto a classe LP, a área abaixo da curva foi de 0,48, mostrando a dificuldade do modelo em identificar corretamente os sinais dessa classe, mesmo considerando sua representatividade no conjunto de validação. Por fim, a classe TOR registrou o menor valor, com 0,0002 de área

abaixo a curva, mostrando o desempenho significativamente deficiente do modelo na identificação da classe minoritária.

Figura 41 - Curva Precision-Recall na classificação de sinais aplicando LPC




Fonte: Elaborado pelo autor.

#### 5.2.1.2.2 Validação externa para dados caracterizados com PCA

A matriz de confusão gerada durante a validação externa do modelo é apresentada na Figura 42, evidenciando a limitação do modelo em identificar as classes VT e LP corretamente quando os sinais se encontram no domínio do tempo.

Figura 42 - Matriz de confusão na classificação de sinais aplicando PCA



Fonte: Elaborado pelo autor.

O relatório das métricas de avaliação, apresentado na Tabela 10 oferece uma análise objetiva do desempenho do modelo na sua capacidade de generalização. O modelo demonstrou uma taxa



de precisão de 100% para a classe VT, indicando que o modelo acertou essa porcentagem nas predições feitas para essa classe. No entanto, sua sensibilidade foi de apenas 1%, o que significa que somente essa porcentagem dos sinais VT foi corretamente identificada pelo modelo. Por fim, Obtém-se um f1-score de 1% mostrando um rendimento baixo na classificação.


Já para a classe LP, o modelo apresentou uma precisão de apenas 19%, indicando que o modelo comete muitos erros ao presumir que sinais de outras classes possam pertencer à classe LP. A sensibilidade de 100% indica que essa porcentagem dos sinais LP foi corretamente identificada. Por fim, obtém-se um f1-score de apenas 32%, mostrando a dificuldade no modelo em classificar a classe LP. Por fim, de forma semelhante acontece com a classe TOR, mostrando uma precisão de 1% e sensibilidade de 93%, notando assim que o modelo consegue identificar as classes LP e TOR, porém o modelo comete muitos erros na hora de presumir um sinal como sendo uma de estes sinais.

Tabela 10 - Reporte de métricas na classificação de sinais aplicando PCA


| Classe | Precisão | Sensibilidade | f1-score |
|--------|----------|---------------|----------|
| VT     | 1,00     | 0,01          | 0,01     |
| LP     | 0,19     | 1,00          | 0,32     |
| TOR    | 0,01     | 0,93          | 0,01     |

A curva ROC- macro mostra que a capacidade de generalização do modelo é deficiente quando lida com novos dados, como pode ser observado na Figura 43 (a). Foi obtido um valor AUC de 0,46, demonstrando que o modelo tem dificuldades para discriminar corretamente entre as classes. A Figura 43 (b) corroborando essa análise ao mostrar a curva ROC para cada uma das classes. Nesse sentido, a classe VT demonstra maior dificuldade em ser identificada, com um AUC de 0,16, seguida da classe LP com AUC de 0,28. Pelo contrário a classe TOR com AUC de 0,93.

Figura 43 - Curva ROC na classificação de sinais aplicando PCA



(a) Curva ROC macro




(b) Curva ROC por classes

Fonte: Elaborado pelo autor.

Também foi analisada a curva *Precision-Recall* para avaliar o desempenho do modelo, revelando um rendimento limitado na classificação, com um área abaixo a curva de 0,17 para a classe LP. Esse valor sugere uma capacidade insuficiente do modelo para discernir de forma eficaz entre as instâncias positivas e negativas dessa classes.

Por outra lado, as classes VT e TOR exibiram uma área abaixo da curva de 0,75 e 0,93, respectivamente. Demonstrando um desempenho aceitável em termos de precisão para a classe VT e sensibilidade na classe TOR. Os resultados obtidos destacam a dificuldade do modelo para diferenciar entre as classes, sendo a TOR a melhor classificada, conforme evidenciado na Figura 44.

Figura 44 - Curva Precision-Recall na classificação de sinais aplicando PCA




Fonte: Elaborado pelo autor.

### 5.2.1.2.3 Validação externa para dados caracterizados com o DAF

A matriz de confusão gerada durante a validação externa do modelo é mostrada na Figura 45, revelando a limitação do modelo em identificar a classe VT corretamente. No entanto, a classificação das classes LP e TOR demonstram um bom desempenho.

Figura 45 - Matriz de confusão na classificação de sinais aplicando DAF



Fonte: Elaborado pelo autor.

O relatório das métricas de avaliação, apresentado na Tabela 11 oferece uma visão detalhada do modelo e sua capacidade de generalização. O modelo demonstrou uma taxa de precisão de 98% para a classe VT, indicando a porcentagem de acerto nas previsões para essa classe (não sendo uma boa métrica para este caso particular). No entanto, sua sensibilidade foi de apenas 2%, indicando que somente essa parcela dos sinais VT no conjunto de validação foi identificada

pelo modelo. Isso resultou em um f1-score de 5%, apontando para um desempenho deficiente na classificação dos sinais VT.

Para a classe LP, o modelo revelou uma precisão de apenas 18%, indicando a ocorrência de erros ao presumir sinais de outras classes como à classe LP. No entanto, a sensibilidade de 99% indica que todos os sinais LP no conjunto de validação foram corretamente identificados. Apesar disso, o f1-score de apenas 31%, mostra a dificuldade do modelo em classificar adequadamente a classe LP.


Por fim, 93% dos sinais da classe TOR no conjunto de validação foram identificados. No entanto, o modelo parece ter dificuldades em distinguir outros tipos de sinais como sendo da classe TOR, acertando apenas 18% das vezes. Isso resultou em um f1-score de 50%, sugerindo que o modelo tem um desempenho moderado na previsão da classe TOR.

Tabela 11 - Reporte de métricas na classificação de sinais aplicando DAF


| Classe | Precisão | Sensibilidade | f1-score |
|--------|----------|---------------|----------|
| VT     | 0,98     | 0,02          | 0,05     |
| LP     | 0,18     | 0,99          | 0,31     |
| TOR    | 0,34     | 0,93          | 0,50     |

A curva ROC- macro demonstra que a capacidade de generalização do modelo é moderada ao lidar com novos dados, conforme ilustrado na Figura 46 (a). Foi obtido um valor AUC de 0,65, demonstrando que o modelo tem dificuldades para discriminar corretamente entre as classes. A Figura 46 (b) corrobora o exposto anteriormente, mostrando a curva ROC para cada uma das classes, sendo as classe VT e LP as que apresentam maior dificuldade em serem identificadas, com um AUC de 0,50 e 0,53, respectivamente. A classe LP obteve um AUC de 0,93. Desta forma é confirmado que as classes introduzidas VT e LP de vulcões distintos no conjunto de validação confundem o modelo de classificação.

Figura 46 - Curva ROC na classificação de sinais aplicando DAF



(a) Curva ROC macro




(b) Curva ROC por classes

Fonte: Elaborado pelo autor.

Ao analisar a curva *Precision-Recall*, representada na Figura 47, permitiu avaliar o desempenho do modelo em termos de precisão de suas predições. Os resultados mostram um ótimo rendimento na classificação da classe TOR, com uma área abaixo a curva de 0,93, embora o número reduzido de sinais para esta classe.

Por outro lado, a curva indica um desempenho moderado para distinguir a classe VT. Devido ao elevado número de sinais (a classe majoritária), observa-se um rendimento aceitável na identificação dos verdadeiros positivos. Finalmente, para a classe LP, a curva mostra um desempenho inferior, evidenciando as dificuldades do modelo em obter taxas mais altas de verdadeiros positivos.

Figura 47 - Curva Precision-Recall na classificação de sinais aplicando o DAF





Fonte: Elaborado pelo autor.

## 5.2.2 Classificação dos dados no domínio da frequência

### 5.2.2.1 Validação Cruzada Estratificada

Conforme mencionado na metodologia, a classificação dos sinais também foi realizada no domínio da frequência. Devido ao desbalanceamento das classes nos sinais do vulcão Galeras, o treinamento do modelo de classificação foi conduzido utilizando a técnica de validação cruzada estratificada. A Figura 48 ilustra o desempenho da validação cruzada por meio da análise da curva ROC para cada uma das abordagens de caracterização empregadas nos sinais de sísmicos.

Figura 48 - Validação cruzada estratificada no modelo de classificação no domínio da frequência



Fonte: Elaborado pelo autor.

O desempenho mostrado após a validação cruzada, conforme evidenciado pelas curvas ROC, revelou um alto rendimento ao utilizar a técnica LFCC, resultando em valores de AUC de 0,99 para todas as classes. Esses resultados sugerem que esta técnica beneficia o processo de classificação.

Entretanto, ao aplicar as técnicas PCA e DAF nos espectros de frequência, observou-se uma pequena redução no desempenho do modelo, evidenciado na classe TOR, com valores de AUC de 0,93 e 0,95, respectivamente, em comparação com os resultados no domínio do tempo.


### 5.2.2.2 Validação interna (Domínio da frequência)

Para avaliar a capacidade preditiva do modelo quando os sinais foram abordados no domínio da frequência, foi aplicada uma validação interna utilizando um conjunto de sinais provenientes do vulcão Galeras que não foram empregadas durante a fase de treinamento.

#### 5.2.2.2.1 Validação interna para dados caracterizados com LFCC

Os resultados da validação interna utilizando os sinais caracterizados com a técnica LFCC do conjunto de validação, apontam que o modelo de classificação consegue identificar corretamente cada uma das classes, como pode ser identificado na Figura 49. É notável que a área abaixo a curva (AUC) para cada uma das classes é de 1,0, demonstrando assim que esta técnica contribui positivamente no processo de classificação para acertar nas predições dos sinais.

Figura 49 - Curva ROC para a validação interna de sinais aplicando LFCC




Fonte: Elaborado pelo autor.

A curva *Precision-Recall* também foi analisada para avaliar esse processo de validação. A Figura 50 ilustra os resultados obtidos. Na curva, é possível identificar que o modelo consegue realizar predições precisas para cada uma das classes dos sinais, reforçando assim que a técnica é adequada para a classificações dos sinais sísmicos.



Figura 50 - Curva Precision-Recall para a validação interna de sinais aplicando LFCC




Fonte: Elaborado pelo autor.

#### 5.2.2.2 Validação interna com caracterização PCA (Domínio da frequência)

Os resultados da validação interna para os sinais no domínio da frequência utilizando a técnica PCA são apresentados na Figura 51. É evidente um bom desempenho para a classe VT, com um AUC de 0,97. Para a classe LP, obteve-se um AUC de 0,94, indicando uma eficiência menor nas predições para essa classe, porém ainda satisfatórias. No entanto, o modelo enfrenta dificuldades ao prever a classe TOR, evidenciado por um AUC de 0,78. É relevante notar que, ao empregar a técnica PCA no domínio da frequência, foram obtidos melhores resultados que quando foi aplicada no domínio do tempo.

Figura 51 - Curva ROC para a validação interna de sinais aplicando PCA



Fonte: Elaborado pelo autor.

A análise da curva *Precision-Recall* pode ser observada na Figura 52. ta curva confirma a

capacidade do o modelo em obter bons resultados na classificação dos sinais VT e LP, com um área abaixo da curva de 1,00 em ambas as classes. A classe TOR, apresentou um área abaixo da curva de 0,97. Contudo, é evidente que os resultados na precisão das classificações pioram quando a técnica PCA é aplicada no domínio da frequência.

Figura 52 - Curva Precision-Recall para a validação interna de sinais aplicando PCA




Fonte: Elaborado pelo autor.

#### 5.2.2.2.3 Validação interna com caracterização DAF (Domínio da frequência)

Quando a técnica DAF é aplicada nos sinais no domínio da frequência, é possível notar uma leve redução no desempenho do modelo em comparação com a aplicação no domínio do tempo. A curva ROC para este experimento está representada na Figura 53. Esta curva indica resultados satisfatórios de classificação para todas as classes com AUC de 1,00, 1,00 e 0,98, para as classes VT, LP e TOR, respectivamente. Isso evidencia que a técnica DAF contribui na classificação dos sinais sísmicos, tanto no domínio do tempo como da frequência.


Figura 53 - Curva ROC para a validação interna de sinais aplicando DAF



Fonte: Elaborado pelo autor.

A curva *Precision-Recall* também indica resultados satisfatórios na classificação dos sinais no domínio da frequência, conforme mostrado na Figura 38. A classe VT alcançou um área abaixo a curva de 1,00. Um desempenho semelhante é observado na classificação para a classe LP, com um área abaixo da curva de 0,99. Por fim, para a classe TOR é obtido um área abaixo a curva de 0,96. Isso evidencia que a técnica DAF permite previsões precisas do modelo para todas as classes, da mesma forma quando é aplicada no domínio do tempo.

Figura 54 - Curva Precision-Recall para a validação interna de sinais aplicando DAF



Fonte: Elaborado pelo autor.


### 5.2.2.3 Validação externa

Para avaliar a capacidade preditiva e de generalização do modelo, optou-se por analisar os resultados obtidos na classificação utilizando a técnica LFCC, devido aos resultados consistentes durante a validação interna do modelo, em comparação com as outras técnicas (PCA e DAF). Estas últimas apresentaram desempenhos similares ao do domínio do tempo no domínio da frequência. A continuação apresenta a análise da contribuição na classificação com dados de sinais externos ao vulcão Galeras, quando os sinais foram caracterizados com a técnica LFCC.

#### 5.2.2.3.1 Validação externa para dados caracterizados com LFCC

A matriz de confusão gerada na validação externa do modelo é apresentada na Figura 55, evidenciando que o modelo não consegue identificar corretamente as classes LP e TOR. No entanto, a classe VT parece demonstrar um bom desempenho.

Figura 55 - Matriz de confusão na classificação de sinais aplicando LFCC



Fonte: Elaborado pelo autor.

O relatório das métricas de avaliação, apresentado na Tabela 12 oferece uma análise objetiva do desempenho do modelo. Para a classe VT, é observada uma alta precisão de 93%, indicando que a maioria dos sinais classificados como VT foram corretamente identificados. No entanto, a sensibilidade indica que apenas 64% dos sinais VT foram corretamente classificados. O f1-score de 76%, mostra um desempenho razoável para esta classe.

Para a classe LP, os resultados revelam uma precisão de 67%, indicando uma taxa moderada de acertos ao classificar essa classe. Entretanto, a sensibilidade sugere que unicamente 31% dos sinais reais da classe LP foram corretamente reconhecidos. Isso fica refletido no valor f1-score de 43%, mostrando um desempenho moderado na capacidade do modelo para detectar a classe LP.


Já para a classe TOR, os resultados mostram uma precisão, sensibilidade e f1-score deficientes, indicando a dificuldade que o modelo tem para identificar as instâncias para essa classe.

Tabela 12 - Reporte de métricas na classificação de sinais aplicando LFCC


| Classe | Precisão | Sensibilidade | f1-score |
|--------|----------|---------------|----------|
| VT     | 0,93     | 0,64          | 0,76     |
| LP     | 0,67     | 0,31          | 0,43     |
| TOR    | 0,0      | 0,01          | 0,0      |

A curva ROC - macro mostra que a capacidade de generalização do modelo é limitada quando lida com novos dados, como pode ser observado na Figura 56 (a). Foi obtido um valor AUC de 0,67, demonstrando que o modelo tem dificuldades para discriminar corretamente entre as classes. A Figura 56 (b) permite a análise da curva ROC para cada uma das classes, sendo as classes VT e LP as que apresentaram maior desempenho em ser identificadas, com AUC de 0,79 e 0,78, respectivamente. Entretanto, a classe TOR com AUC de 0,45, sugere que o modelo tem dificuldades para identificar os sinais dessa classe.

Figura 56 - Curva ROC na classificação de sinais aplicando LFCC



(a) Curva ROC macro



(b) Curva ROC por classes


Fonte: Elaborado pelo autor.

Também foi analisada a curva *Precision-Recall*, conforme visualizado na Figura 57, que oferece detalhes objetivos sobre o desempenho do modelo na classificação.

Para a classe VT, foi registrada uma área abaixo da curva de 0,94, evidenciando a capacidade que o modelo tem para prever corretamente essa classe, o qual é significativo ao ser a classe majoritária no conjunto de validação.

Enquanto a classe LP, a área abaixo a curva foi de 0,53, mostrando a incerteza do modelo em identificar corretamente os sinais dessa classe. Por fim, a classe TOR registrou o menor valor, com 0,0002 de área abaixo a curva, mostrando que o desempenho significativamente deficiente na identificação da classe minoritária.

Figura 57 - Curva Precision-Recall na classificação de sinais aplicando LFCC



Fonte: Elaborado pelo autor.

## 6 CONCLUSÕES

A aplicação de técnicas convencionais de caracterização, como LPC e LFCC para obter representações compactas dos sinais, contribui na classificação dos mesmos. Ambas as técnicas mostraram gerar padrões homogêneos das características intrínsecas, definindo claramente cada classe. A análise de correlação identificou uma forte correlação entre os sinais registrados em Galeras, mas não revelou relações fortes com os sinais registrados nos vulcões Etna e Volcano da Itália. A análise de discriminante linear para ambas as técnicas indicou *clusters* densos sem dispersão de dados, embora com alguma sobreposição aparente.

A técnica de caracterização PCA mostrou-se incapaz de gerar padrões homogêneos das características intrínsecas nos sinais. Os padrões dos componentes principais não foram claramente definidos e, por tanto, não permitiram uma distinção clara entre as classes se sísmicas. A análise de correlação evidenciou a ausência de correlação entre classes, tanto no domínio do tempo quanto na frequência. A análise de discriminante revelou uma separabilidade nula entre as classes, tanto para os sinais no domínio do tempo quanto no da frequência, o que pode afetar o desempenho do modelo de classificação.

A técnica de caracterização proposta, DAF, mostra padrões de características homogênea, proporcionando uma clara definição para cada uma das classes quando aplicada no domínio do tempo. No entanto, as representações obtidas no domínio da frequência parecem não distinguir claramente as classes. A análise de correlação mostrou uma maior relação entre os sinais dos vulcões na Itália do que com os sinais registrados no Galeras. Por fim, a análise de discriminante linear demonstrou alta separabilidade entre as classes somente quando a técnica foi aplicada no domínio do tempo.

Os resultados obtidos com a validação cruzada estratificada, utilizando os dados de sinais registrados no vulcão Galeras foram satisfatórios. Especialmente, quando as técnicas LPC e DAF foram aplicadas no domínio do tempo, e LFCC e DAF no domínio da frequência. Contudo, a técnica PCA mostrou algumas limitações, sendo mais evidente quando a validação cruzada estratificada é aplicada no modelo de classificação no domínio do tempo.

Os resultados da validação interna, usando o conjunto de validação é composto por sinais registradas no vulcão Galeras, demonstram que o modelo de classificação consegue discriminar todas as classes de maneira satisfatória. Isto é evidente quando as técnicas de caracterização LPC, LFCC e DAF são aplicadas, tanto no domínio de tempo quanto no da frequência. No entanto, quando a técnica PCA é empregada, o modelo consegue identificar sem dificuldade as



classes VT e LP. Porém, a classe TOR apresenta um desempenho deficiente, especialmente no domínio do tempo.

Quando os dados dos sinais provenientes dos vulcões da Itália foram adicionados ao conjunto de validação, revelaram deficiências de generalização no classificador. Os piores resultados foram obtidos quando a técnica PCA é aplicada na caracterização dos sinais, evidenciando maiores dificuldades para identificar a classe TOR, tanto no domínio do tempo quando no da frequência. Ao empregar a técnica LPC, observou-se um desempenho deficiente do modelo para as classes VT e principalmente TOR. No domínio da frequência, a aplicação da técnica LFCC demonstrou um desempenho aceitável para o reconhecimento das classes VT e LP. No entanto, o modelo foi incapaz de identificar sinais da classe TOR. Por fim, ao empregar a técnica proposta DAF, obteve-se resultados de classificação satisfatórios apenas para a classe TOR, destacando que esta técnica possibilita a correta discriminação da classe minoritária. Porém, a classificação dos sinais VT e LP foi deficiente.

A técnica de caracterização porposta, DAF, destaca-se como uma abordagem inovadora na caracterização de sinais, gerando representações compactas que permitem a definição das classes e apresenta resultados comparáveis às técnicas convencionais como LPC e LFCC. Esta técnica contribui satisfatoriamente no processo de classificação quando o modelo é confrontado com sinais novos, mas provenientes do mesmo contexto vulcânico dos sinais utilizados no treinamento. Também vale ressaltar que, embora esta técnica não tenha obtido bons resultados na generalização do modelo ao classificar sinais de vulcões diferentes, ela oferece uma boa discriminação boa da classe minoritária.

## 6.1 Sugestões para trabalhos futuros

Considerando os resultados obtidos ao aplicar diferentes técnicas de caracterização aos sinais e sua influência no modelo de classificação, seria vantajoso combinar as técnicas que apresentaram os melhores resultados. Essa abordagem permitiria que o modelo aprenda a distinguir de maneira mais eficaz entre as diferentes classes. A combinação das técnicas pode ser realizada por meio de ponderação dos resultados no modelo do classificador, uma vez que algumas dessas técnicas demonstraram ser mais eficazes na previsão de determinadas classes.

Alem disso, seria proveitoso obter conjuntos de dados de vulcões adicionais, permitindo que o modelo de classificação aprenda representações distintas para cada classe. Dessa forma, a capacidade de generalização do modelo seria ampliada.

## REFERÊNCIAS

- AKI, K. State of the art in volcanic seismology. **Volcanic Seismology**, Springer, Berlin, DE, p. 3–10, 1992. Citado na página 15.
- AKI, K. et al. Seismic properties of a shallow magma reservoir in kilauea iki by active and passive experiments. **Journal of Geophysical Research: Solid Earth**, Wiley Online Library, Boston, US, v. 83, n. B5, p. 2273–2282, 1978. Citado 2 vezes nas páginas 23 e 56.
- ALI, H. et al. Imbalance class problems in data mining: A review. **Indonesian Journal of Electrical Engineering and Computer Science**, Yakarta, ID, v. 14, n. 3, p. 1560–1571, 2019. Citado na página 17.
- ALLEN, R. V. Automatic earthquake recognition and timing from single traces. **Bulletin of the seismological society of America**, The Seismological Society of America, California, US, v. 68, n. 5, p. 1521–1532, 1978. Citado na página 41.
- ALPARONE, S. et al. Time-space variation of volcano-seismic events at la fossa (vulcano, aeolian islands, italy): new insights into seismic sources in a hydrothermal system. **Bulletin of Volcanology**, Springer, Heidelberg, DE, v. 72, p. 803–816, 2010. Citado na página 23.
- ÁLVAREZ, I. et al. Improving feature extraction in the automatic classification of seismic events. application to colima and arenal volcanoes. In: IEEE. **2009 IEEE International Geoscience and Remote Sensing Symposium**. Cape Town, ZA, 2009. v. 4, p. IV–526. Citado 2 vezes nas páginas 54 e 56.
- ALVAREZ, I. et al. Discriminative feature selection for automatic classification of volcano-seismic signals. **IEEE Geoscience and Remote Sensing Letters**, IEEE, New Jersey, US, v. 9, n. 2, p. 151–155, 2011. Citado na página 45.
- ANDERSON, K. R. Automatic analysis of microearthquake network data. **Geoexploration**, Elsevier, Amsterdam, NL, v. 16, n. 1-2, p. 159–175, 1978. Citado na página 41.
- APOLLONI, B. et al. Support vector machines and mlp for automatic classification of seismic signals at stromboli volcano. In: **Proc. 19th Italian Workshop Neural Nets**. Salerno, IT: [s.n.], 2009. v. 204, p. 116. Citado na página 42.
- ARÁMBULA-MENDOZA, R. et al. Seismic activity that accompanied the effusive and explosive eruptions during the 2004–2005 period at volcán de colima, mexico. **Journal of Volcanology and Geothermal Research**, Elsevier, v. 205, n. 1-2, p. 30–46, 2011. Citado na página 30.
- ARÁMBULA-MENDOZA, R. et al. Tremor and its duration-amplitude distribution at popocatepetl volcano, mexico. **Geophysical Research Letters**, Wiley Online Library, New Jersey, US, v. 43, n. 17, p. 8994–9001, 2016. Citado 3 vezes nas páginas 29, 30 e 31.

- AUSTIN, S. Mount st. helens and catastrophism. In: **Proceedings of the International Conference on Creationism**. Ohio, US: [s.n.], 1986. v. 1, n. 1, p. 5. Citado na página 35.
- AVOSSA, C.; GIUDICEPIETRO, F.; MARINARO, M.; SCARPETTA, S. Supervised and unsupervised analysis applied to strombolian eq. In: SPRINGER. **Neural Nets: 14th Italian Workshop on Neural Nets, WIRN VIETRI 2003, June 4-7, 2003. Revised Papers 14**. Vietri sul Mare, IT, 2003. p. 173–178. Citado na página 44.
- BALDI, P. Autoencoders, unsupervised learning, and deep architectures. In: JMLR WORKSHOP AND CONFERENCE PROCEEDINGS. **Proceedings of ICML workshop on unsupervised and transfer learning**. New York, US, 2012. p. 37–49. Citado na página 72.
- BANKS, N. G.; TILLING, R. I.; HARLOW, D. H.; EWERT, J. W. Volcano monitoring and short-term forecasts. In: **Volcanic Hazards**. Washington-DC, US: American Geophysical Union, 1989. v. 1, p. 81–102. Citado na página 15.
- BAUM, L. E.; PETRIE, T. Statistical inference for probabilistic functions of finite state markov chains. **The annals of mathematical statistics**, JSTOR, Ohaio, US, v. 37, n. 6, p. 1554–1563, 1966. Citado na página 46.
- BAUM, L. E.; PETRIE, T.; SOULES, G.; WEISS, N. A maximization technique occurring in the statistical analysis of probabilistic functions of markov chains. **The annals of mathematical statistics**, JSTOR, v. 41, n. 1, p. 164–171, 1970. Citado na página 46.
- BELLMAN, R. E.; DREYFUS, S. E. **Applied dynamic programming**. New Jersey, US: Princeton university press, 2015. v. 2050. Citado na página 53.
- BELLMAN, R. E.; ROTH, R. S. **The Bellman continuum: a collection of the works of Richard E. Bellman**. Kathmandu, NP: World Scientific, 1986. Citado na página 53.
- BEN-DAVID, S. et al. A theory of learning from different domains. **Machine learning**, Springer, New York, US, v. 79, p. 151–175, 2010. Citado na página 44.
- BENBRAHIM, M.; DAOUDI, A.; BENJELLOUN, K.; IBENBRAHIM, A. Discrimination of seismic signals using artificial neural networks. **International Journal of Computer and Information Engineering**, Citeseer, New Delhi, IN, v. 1, n. 4, p. 984–987, 2007. Citado na página 58.
- BENGIO, Y.; COURVILLE, A.; VINCENT, P. Representation learning: A review and new perspectives. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, New Jersey, US, v. 35, n. 8, p. 1798–1828, 2013. Citado 2 vezes nas páginas 71 e 72.
- BENGIO, Y.; DELALLEAU, O. On the expressive power of deep architectures. In: SPRINGER. **International conference on algorithmic learning theory**. Heidelberg, DE, 2011. p. 18–36. Citado na página 72.
- BENGIO, Y. et al. Learning deep architectures for ai. **Foundations and trends® in Machine Learning**, Now Publishers, Inc., Miami, US, v. 2, n. 1, p. 1–127, 2009. Citado na página 71.
- BENÍTEZ, M. C. et al. Continuous hmm-based seismic-event classification at deception island, antarctica. **IEEE Transactions on Geoscience and remote sensing**, IEEE, New Jersey, US,

v. 45, n. 1, p. 138–146, 2006. Citado 4 vezes nas páginas 16, 42, 46 e 59.

BHATTI, S. M. et al. Automatic detection of volcano-seismic events by modeling state and event duration in hidden markov models. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 324, p. 134–143, 2016. Citado na página 59.

BI, J.; ZHANG, C. An empirical comparison on state-of-the-art multi-class imbalance learning algorithms and a new diversified ensemble learning scheme. **Knowledge-Based Systems**, Elsevier, Amsterdam, NL, v. 158, p. 81–93, 2018. Citado na página 16.

BICEGO, M.; ACOSTA-MUNOZ, C.; OROZCO-ALZATE, M. Classification of seismic volcanic signals using hidden-markov-model-based generative embeddings. **IEEE transactions on geoscience and remote sensing**, IEEE, New Jersey, US, v. 51, n. 6, p. 3400–3409, 2012. Citado na página 16.

BISHOP, C. M. et al. **Neural networks for pattern recognition**. Osford, UK: Oxford university press, 1995. Citado 2 vezes nas páginas 17 e 53.

BLANDFORD, R. R. Seismic event discrimination. **Bulletin of the Seismological Society of America**, The Seismological Society of America, California, US, v. 72, n. 6B, p. S69–S87, 1982. Citado na página 41.

BRUSIL, C. et al. A semi-supervised approach for microseisms classification from cotopaxi volcano. In: IEEE. **2019 IEEE Latin American Conference on Computational Intelligence (LA-CCI)**. Recife, BR, 2019. p. 1–6. Citado 2 vezes nas páginas 17 e 58.

BUENO, A. et al. Volcano-seismic transfer learning and uncertainty quantification with bayesian neural networks. **IEEE Transactions on Geoscience and Remote Sensing**, v. 58, n. 2, p. 892–902, 2020. Citado 3 vezes nas páginas 16, 42 e 47.

CANARIO, J. P. et al. In-depth comparison of deep artificial neural network architectures on seismic events classification. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 401, p. 106881, 2020. Citado na página 44.

CANNATA, A. et al. Multiparametric approach in investigating volcano-hydrothermal systems: the case study of vulcano (aeolian islands, italy). **Pure and applied geophysics**, Springer, Cham, CH, v. 169, p. 167–182, 2012. Citado na página 23.

CÁRDENAS-PEÑA, D.; OROZCO-ALZATE, M.; CASTELLANOS-DOMINGUEZ, G. Selection of time-variant features for earthquake classification at the nevado-del-ruiz volcano. **Computers & geosciences**, Elsevier, v. 51, p. 293–304, 2013. Citado 4 vezes nas páginas 42, 43, 46 e 59.

CARNIEL, R. et al. Neural networks and dynamical system techniques for volcanic tremor analysis. Roma, IT, 1996. Citado na página 41.

CASTRO-CABRERA, P. et al. Adaptive classification using incremental learning for seismic-volcanic signals with concept drift. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 413, p. 107211, 2021. Citado na página 42.

CASTRO-CABRERA, P. A. et al. A comparison between time-frequency and cepstral feature

representations for the classification of seismic-volcanic signals. In: SPRINGER. **Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 19th Iberoamerican Congress, CIARP 2014, November 2-5, 2014. Proceedings 19**. Puerto Vallarta, MX, 2014. p. 440–447. Citado 3 vezes nas páginas 54, 56 e 58.

CHAN, A. D.; ENGLEHART, K.; HUDGINS, B.; LOVELY, D. F. Hidden markov model classification of myoelectric signals in speech. **IEEE Engineering in Medicine and Biology Magazine**, IEEE, v. 21, n. 5, p. 143–146, 2002. Citado na página 42.

CHEN, C. Seismic pattern recognition. **Geoexploration**, Elsevier, Amsterdam, NL, v. 16, n. 1-2, p. 133–146, 1978. Citado na página 41.

CHESTER, D. K.; DIBBEN, C. J.; DUNCAN, A. M. Volcanic hazard assessment in western europe. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 115, n. 3-4, p. 411–435, 2002. Citado na página 15.

CHOUET, B. Volcano seismology. **Pure and applied geophysics**, Springer, Cham, CH, v. 160, p. 739–788, 2003. Citado 2 vezes nas páginas 24 e 36.

CHOUET, B. A. Long-period volcano seismicity: its source and use in eruption forecasting. **Nature**, Nature Publishing Group, London, UK, v. 380, n. 6572, p. 309–316, 1996. Citado na página 27.

CHOUET, B. A.; MATOZA, R. S. A multi-decadal view of seismic methods for detecting precursors of magma movement and eruption. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 252, p. 108–175, 2013. Citado 3 vezes nas páginas 24, 36 e 37.

CHOUET, B. A. et al. Precursory swarms of long-period events at redoubt volcano (1989–1990), alaska: their origin and use as a forecasting tool. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 62, n. 1-4, p. 95–135, 1994. Citado 2 vezes nas páginas 36 e 41.

CORPORATION, R.; BELLMAN, R. **Adoptive control processes: A guided tour**. Florida, US: University Press, 1961. Citado na página 17.

CORTÉS, G. et al. Evaluating robustness of a hmm-based classification system of volcano-seismic events at colima and popocatepetl volcanoes. In: IEEE. **2009 IEEE International Geoscience and Remote Sensing Symposium**. Cape Town, ZA, 2009. v. 2, p. II–1012. Citado 3 vezes nas páginas 42, 46 e 59.

CORTÉS, G. et al. A comparative study of dimensionality reduction algorithms applied to volcano-seismic signals. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, IEEE, New Jersey, US, v. 9, n. 1, p. 253–263, 2015. Citado 5 vezes nas páginas 17, 53, 54, 55 e 69.

CORTÉS, G. et al. Parallel system architecture (psa): An efficient approach for automatic recognition of volcano-seismic events. **Journal of Volcanology and Geothermal Research**, Elsevier, v. 271, p. 1–10, 2014. Citado 2 vezes nas páginas 17 e 45.

CURILEM, G. et al. Classification of seismic signals at villarrica volcano (chile) using neural

networks and genetic algorithms. **Journal of volcanology and geothermal research**, Elsevier, Amsterdam, NL, v. 180, n. 1, p. 1–8, 2009. Citado na página 44.

CURILEM, M. et al. Feature selection for discrimination between volcanic and tectonic events of the Llaima volcano (chile). In: IET. **International Conference on Pattern Recognition Systems (ICPRS-16)**. [S.l.], 2016. p. 1–5. Citado na página 59.

CURILEM, M. et al. Pattern recognition applied to seismic signals of the Llaima volcano (chile): An analysis of the events' features. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 282, p. 134–147, 2014. Citado 2 vezes nas páginas 42 e 43.

DAVIS, S.; MERMELSTEIN, P. Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. **IEEE transactions on acoustics, speech, and signal processing**, IEEE, New Jersey, US, v. 28, n. 4, p. 357–366, 1980. Citado na página 59.

DAVIS, S.; MERMELSTEIN, P. Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. **IEEE transactions on acoustics, speech, and signal processing**, IEEE, v. 28, n. 4, p. 357–366, 1980. Citado na página 68.

DONDIN, F. J.-Y. et al. The university of the west indies-seismic research centre volcano monitoring network: Evolution since 1953 and challenges in maintaining a state-of-the-art network in a small island economy. **Geosciences**, MDPI, Basel, CH, v. 9, n. 2, p. 71, 2019. Citado na página 16.

DOWLA, F. U.; TAYLOR, S. R.; ANDERSON, R. W. Seismic discrimination with artificial neural networks: preliminary results with regional spectral data. **Bulletin of the Seismological Society of America**, The Seismological Society of America, California, US, v. 80, n. 5, p. 1346–1373, 1990. Citado na página 41.

ERTEL, W. **Introduction to artificial intelligence**. Cham, CH: Springer, 2018. Citado na página 70.

ESPOSITO, A. et al. Automatic discrimination among landslide, explosion-quake, and microtremor seismic signals at stromboli volcano using neural networks. **Bulletin of the Seismological Society of America**, GeoScienceWorld, Californai, US, v. 96, n. 4A, p. 1230–1240, 2006. Citado na página 44.

ESPOSITO, A. M. et al. Automatic recognition of landslides based on neural network analysis of seismic signals: an application to the monitoring of stromboli volcano (southern italy). **Pure and Applied Geophysics**, Springer, Cham, CH, v. 170, p. 1821–1832, 2013. Citado 2 vezes nas páginas 16 e 59.

ESPOSITO, A. M. et al. Neural analysis of seismic data: Applications to the monitoring of mt. vesuvius. **Annals of Geophysics**, Istituto Nazionale di Geofisica e Vulcanologia, Rome, IT, 2013. Citado na página 44.

EZIN, E. C. et al. Automatic discrimination of earthquakes and false events in seismological recording for volcanic monitoring. In: SPRINGER. **Neural Nets: 13th Italian Workshop on Neural Nets, WIRN VIETRI 2002, May 30–June 1, Revised Papers 13**. Vietri sul Mare, IT,

2002. p. 140–145. Citado na página 42.

FALCIN, A. et al. A machine-learning approach for automatic classification of volcanic seismicity at la soufrière volcano, guadeloupe. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 411, p. 107151, 2021. Citado na página 42.

FALSAPERLA, S.; GRAZIANI, S.; NUNNARI, G.; SPAMPINATO, S. Automatic classification of volcanic earthquakes by using multi-layered neural networks. **Natural Hazards**, Springer, Cham, CH, v. 13, p. 205–228, 1996. Citado 2 vezes nas páginas 41 e 44.

FARRELL, W.; CA, S.-C. L. J. Automatic seismic discrimination system (asdis). Virginia, US, 1982. Citado na página 41.

FAURE, C.; SOLDANO, H.; PYL, T. V. D. Descriptive methods and processing of seismic signals. **Geoexploration**, Elsevier, Amsterdam, NL, v. 23, n. 1, p. 17–34, 1984. Citado na página 41.

FAWCETT, T. An introduction to ROC analysis. **Pattern recognition letters**, Elsevier, Amsterdam, NL, v. 27, n. 8, p. 861–874, 2006. Citado na página 80.

GALLI, L. et al. Wavelet decomposition and advanced denoising techniques for analysis and classification of seismic signals. In: **VOLUME Project VOLcanoes: Understanding subsurface mass moveMEnt**. Dublin, IE: [s.n.], 2009. Citado na página 43.

GAO, K.; HUANG, L.; CLADOUHOS, T. Seismic characterization of the blue mountain geothermal field. **Energies**, MDPI, Basel, CH, v. 16, n. 15, p. 5822, 2023. Citado na página 58.

GARCÍA, V.; SÁNCHEZ, J. S.; MOLLINEDA, R. A. On the effectiveness of preprocessing methods when dealing with different levels of class imbalance. **Knowledge-Based Systems**, Elsevier, Amsterdam, NL, v. 25, n. 1, p. 13–21, 2012. Citado na página 17.

GENG, Z.; WANG, Y. Automated design of a convolutional neural network with multi-scale filters for cost-efficient seismic data classification. **Nature communications**, Nature Publishing Group UK London, v. 11, n. 1, p. 3311, 2020. Citado na página 16.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Massachusetts, US: MIT press, 2016. Citado na página 69.

GÓMEZ, D. M. et al. Tornillo seismic events at galeras volcano, Colombia: a summary and new information from broadband three-component measurements. Rome, IT, 1999. Citado na página 27.

HAGERTY, M.; BENITES, R. Tornillos beneath tongariro volcano, new zealand. **Journal of volcanology and geothermal research**, Elsevier, Amsterdam, NL, v. 125, n. 1-2, p. 151–169, 2003. Citado na página 27.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. H.; FRIEDMAN, J. H. **The elements of statistical learning: data mining, inference, and prediction**. Cham, CH: Springer, 2009. v. 2. Citado na página 65.

HAVSKOV, J.; ALGUACIL, G. **Instrumentation in earthquake seismology**. Cham, CH: Springer, 2004. v. 358. Citado na página 35.

HELZ, R. T. Drilling report and core logs for the 1988 drilling of kilauea iki lava lake, kilauea volcano, hawaii, with summary descriptions of the occurrence of foundered crust and fractures in the drill core. **Open-File Report**, US Geological Survey, Virginia, US, 1993. Citado na página 23.

HERRERA, R. H.; HAN, J.; BAAN, M. van der. Applications of the synchrosqueezing transform in seismic time-frequency analysis. **Geophysics**, Society of Exploration Geophysicists, Oklahoma, US, v. 79, n. 3, p. V55–V64, 2014. Citado na página 60.

HINTON, G. A practical guide to training restricted boltzmann machines. **Momentum**, Toronto, CA, v. 9, n. 1, p. 926, 2010. Citado na página 71.

HODGES, J.; FIX, E. An important contribution to nonparametric discriminant analysis and density estimation: Commentary on fix and hodes (1951). **International Statistical Review**, West Sussex, UK, 1989. Citado na página 43.

HOOGENBOEZEM, R. Automatic classification of segmented seismic recordings at the nevado del ruiz volcano, columbia. Netherlands, 2010. Citado na página 54.

HOTELLING, H. Analysis of a complex of statistical variables into principal components. **Journal of educational psychology**, Warwick & York, Washington-DC, US, v. 24, n. 6, p. 417, 1933. Citado 3 vezes nas páginas 18, 59 e 65.

HOUGHTON, B. et al. **The encyclopedia of volcanoes**. Amsterdam, NL: Elsevier, 2015. Citado 5 vezes nas páginas 32, 34, 35, 37 e 39.

HUANG, N. E. et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. **Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences**, The Royal Society, London, UK, v. 454, n. 1971, p. 903–995, 1998. Citado na página 59.

HYVÄRINEN, A.; OJA, E. Independent component analysis: algorithms and applications. **Neural networks**, Elsevier, Amsterdam, NL, v. 13, n. 4-5, p. 411–430, 2000. Citado na página 59.

IBÁÑEZ, J. M. et al. The classification of seismo-volcanic signals using hidden markov models as applied to the stromboli and etna volcanoes. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 187, n. 3-4, p. 218–226, 2009. Citado 5 vezes nas páginas 16, 42, 46, 58 e 59.

IBÁÑEZ, J. M. et al. The classification of seismo-volcanic signals using hidden markov models as applied to the stromboli and etna volcanoes. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 187, n. 3-4, p. 218–226, 2009. Citado na página 59.

IBÁÑEZ, J. M. et al. Seismovolcanic signals at deception island volcano, antarctica: Wave field analysis and source modeling. **Journal of Geophysical Research: Solid Earth**, Wiley Online Library, New Jersey, US, v. 105, n. B6, p. 13905–13931, 2000. Citado na página 24.



- IBARRA, O. C. **Detección y clasificación automática de registros sísmicos en el Observatorio Vulcanológico y Sismológico de Pasto utilizando redes neuronales artificiales**. 2011. Dissertação (Mestrado) — Universidad Nacional de Colombia Colombia, Bogotá, CO, 2011. Citado 4 vezes nas páginas 16, 17, 29 e 33.
- IMBÒ, G. **Sismicità del parossismo vesuviano del marzo 1944**. Genova, IT: Stabilimento tipografico G. Genovese, 1954. Citado na página 23.
- INGV, W. **World Organization of Volcano Observatories (WOVO) Map**. 2023. Disponível em: <<https://wovo.iavceivolcano.org/observatory-map>>. Citado na página 22.
- JOUSSET, P.; HABERLAND, C.; BAUER, K.; ARNASON, K. Hengill geothermal volcanic complex (iceland) characterized by integrated geophysical observations. **Geothermics**, Elsevier, Amsterdam, NL, v. 40, n. 1, p. 1–24, 2011. Citado na página 58.
- KHATTAK, G. et al. Automatic classification of seismic signals of the chilean llaima volcano using cartesian genetic programming based artificial neural network. IET, Stevenage, UK, 2017. Citado na página 44.
- KOLLER, D.; FRIEDMAN, N. **Probabilistic graphical models: principles and techniques**. Massachusetts, US: MIT press, 2009. Citado na página 45.
- KROGH, A.; HERTZ, J. A simple weight decay can improve generalization. **Advances in neural information processing systems**, Maryland, US, v. 4, 1991. Citado na página 71.
- KUBAT, M. Introduction to machine learning. In: **Advanced Topics in Artificial Intelligence: International Summer School Prague, Czechoslovakia, July 6–17, 1992 Proceedings**. Cham, CH: Springer, 2005. p. 104–138. Citado 3 vezes nas páginas 17, 69 e 70.
- KVAERNA, T.; RINGDAL, F. Integrated array and three-component processing using a seismic microarray. **Bulletin of the Seismological Society of America**, The Seismological Society of America, California, US, v. 82, n. 2, p. 870–882, 1992. Citado na página 56.
- LAHR, J. C. et al. Earthquake classification, location, and error analysis in a volcanic environment: Implications for the magmatic system of the 1989–1990 eruptions at redoubt volcano, alaska. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 62, n. 1-4, p. 137–151, 1994. Citado 3 vezes nas páginas 15, 23 e 25.
- LANGER, H. et al. Synopsis of supervised and unsupervised pattern classification techniques applied to volcanic tremor data at mt etna, italy. **Geophysical Journal International**, Blackwell Publishing Ltd Oxford, UK, v. 178, n. 2, p. 1132–1144, 2009. Citado 2 vezes nas páginas 43 e 44.
- LANGER, H.; FALSAPERLA, S.; POWELL, T.; THOMPSON, G. Automatic classification and a-posteriori analysis of seismic event identification at soufrière hills volcano, montserrat. **Journal of volcanology and geothermal research**, Elsevier, Amsterdam, NL, v. 153, n. 1-2, p. 1–10, 2006. Citado 2 vezes nas páginas 42 e 44.
- LARA-CUEVA, R. et al. Time and frequency feature selection for seismic events from cotopaxi volcano. In: IEEE. **2015 Asia-Pacific Conference on Computer Aided System Engineering**. Quito, EC, 2015. p. 129–134. Citado na página 56.

- LARA-CUEVA, R. A. et al. Automatic recognition of long period events from volcano tectonic earthquakes at cotopaxi volcano. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, New Jersey, US, v. 54, n. 9, p. 5247–5257, 2016. Citado na página 43.
- LARA, P. E. E. et al. Automatic multichannel volcano-seismic classification using machine learning and emd. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, IEEE, New Jersey, US, v. 13, p. 1322–1331, 2020. Citado na página 60.
- LATTER, J. H. Volcanological observations at tongariro national park. ii: Types and classification of volcanic earthquakes, 1976-1978. **Report-Geophysics Division**, Wellington, NZ, n. 150, 1979. Citado 2 vezes nas páginas 24 e 25.
- LI, J.; BARRON, A. Mixture density estimation. **Advances in neural information processing systems**, Maryland, US, v. 12, 1999. Citado na página 45.
- LIU, H.-H. A rule-based system for automatic seismic discrimination. **Pattern Recognition**, Elsevier, Amsterdam, NL, v. 18, n. 6, p. 459–463, 1985. Citado na página 41.
- LIU, H.-H.; FU, K.-S. An application of syntactic pattern recognition to seismic discrimination. **IEEE Transactions on Geoscience and Remote sensing**, IEEE, New Jersey, US, n. 2, p. 125–132, 1983. Citado na página 43.
- LIU, Z.; HUANG, J.; WANG, Y. Classification tv programs based on audio information using hidden markov model. In: IEEE. **1998 IEEE Second Workshop on Multimedia Signal Processing (Cat. No. 98EX175)**. California, US, 1998. p. 27–32. Citado na página 42.
- LONDOÑO, J. M.; KUMAGAI, H.; TORRES, R. Temporal change of the magma plumbing system at galeras volcano, colombia, revealed by repeated seismic tomography in 2009–2018. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 406, p. 107075, 2020. Citado na página 21.
- MAGOTRA, N.; HUSH, D.; BIBBO, J.; CHAEL, E. Seismic signal discrimination using adaptive system parameters. In: IEEE. **Proceedings of the 33rd Midwest Symposium on Circuits and Systems**. Calgary, CA, 1990. p. 84–87. Citado na página 41.
- MAKHOUL, J. Linear prediction: A tutorial review. **Proceedings of the IEEE**, IEEE, New Jersey, US, v. 63, n. 4, p. 561–580, 1975. Citado 3 vezes nas páginas 17, 59 e 66.
- MALFANTE, M. et al. Machine learning for volcano-seismic signals: Challenges and perspectives. **IEEE Signal Processing Magazine**, IEEE, New Jersey, US, v. 35, n. 2, p. 20–30, 2018. Citado 3 vezes nas páginas 16, 17 e 41.
- MANLEY, G. F. et al. A deep active learning approach to the automatic classification of volcano-seismic events. **Frontiers in Earth Science**, Frontiers, Lausanne, CH, v. 10, p. 807926, 2022. Citado na página 42.
- MARTÍNEZ, V. L. et al. Advanced signal recognition methods applied to seismo-volcanic events from planchon peteroa volcanic complex: Deep neural network classifier. **Journal of South American Earth Sciences**, Elsevier, Amsterdam, NL, v. 107, p. 103115, 2021. Citado 2 vezes nas páginas 67 e 69.

- MASOTTI, M. et al. Tremorec: a software utility for automatic classification of volcanic tremor. **Geochemistry, Geophysics, Geosystems**, Wiley Online Library, New Jersey, US, v. 9, n. 4, 2008. Citado na página 43.
- MATTIA, M. et al. Combined seismic and geodetic analysis before, during, and after the 2018 mount etna eruption. **Geochemistry, Geophysics, Geosystems**, Wiley Online Library, v. 21, n. 9, p. e2020GC009218, 2020. Citado 2 vezes nas páginas 21 e 22.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, Cham, CH, v. 5, p. 115–133, 1943. Citado 2 vezes nas páginas 43 e 44.
- MCGUIRE, B.; KILBURN, C. R.; MURRAY, J. **Monitoring active volcanoes: strategies, procedures and techniques**. [S.l.]: Taylor & Francis, 2022. Citado na página 15.
- MINAKAMI, T. Seismology of volcanoes in japan. In: **Developments in solid earth geophysics**. Amsterdam, NL: Elsevier, 1974. v. 6, p. 1–27. Citado na página 25.
- MORENO, G. C. **Reconocimiento de señales sismo-volcánicas mediante canales específicos basados en modelos ocultos de Markov**. 2015. Tese (Doutorado) — Universidad de Granada, 2015. Citado 3 vezes nas páginas 16, 17 e 46.
- MURPHY, K. P. et al. Dynamic bayesian networks. **Probabilistic Graphical Models, M. Jordan**, [s.l.], v. 7, p. 431, 2002. Citado na página 46.
- NEUBERG, J.; LUCKETT, R.; BAPTIE, B.; OLSEN, K. Models of tremor and low-frequency earthquake swarms on montserrat. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 101, n. 1-2, p. 83–104, 2000. Citado na página 30.
- NG, W. W. et al. Dual autoencoders features for imbalance classification problem. **Pattern Recognition**, Elsevier, Amsterdam, NL, v. 60, p. 875–889, 2016. Citado 3 vezes nas páginas 17, 71 e 72.
- NYQUIST, H. Certain topics in telegraph transmission theory. **Transactions of the American Institute of Electrical Engineers**, IEEE, New Jersey, US, v. 47, n. 2, p. 617–644, 1928. Citado na página 62.
- OHRNBERGER, M. **Continuous automatic classification of seismic signals of volcanic origin at Mt. Merapi, Java, Indonesia**. 2001. Tese (Doutorado) — Potsdam, Univ., Diss., 2001, 2001. Citado na página 56.
- OMORI, F. Chapter i. General considerations (the eruptions and earthquakes of the Asama-Yama). **Bulletin of the Imperial Earthquake Investigation Committee**, [s.l.], v. 6, n. 1, p. 1–16, 1912. Citado na página 23.
- OPPENHEIM, A. V. **Discrete-time signal processing**. New Delhi, IN: Pearson Education India, 1999. Citado na página 67.
- OPPENHEIM, A. V.; SCHAFER, R. W. From frequency to quefrency: A history of the cepstrum. **IEEE signal processing Magazine**, IEEE, New Jersey, US, v. 21, n. 5, p. 95–106, 2004. Citado 2 vezes nas páginas 59 e 68.

- OROZCO-ALZATE, M.; ACOSTA-MUÑOZ, C.; LONDOÑO-BONILLA, J. M. The automated identification of volcanic earthquakes: concepts, applications and challenges. **Earthquake Research and Analysis-Seismology, Seismotectonic and Earthquake Geology**, InTech Rijeka, [s.l], p. 345–370, 2012. Citado 2 vezes nas páginas 46 e 54.
- OROZCO, M.; GARCÍA, M. E.; DUIN, R. P.; CASTELLANOS, C. G. Dissimilarity-based classification of seismic signals at nevado del ruiz volcano. **Earth Sciences Research Journal**, Maestría en Geofísica, Departamento de Geociencias, Facultad de Ciencias . . . , Bogotá, CO, v. 10, n. 2, p. 57–66, 2006. Citado na página 42.
- Osservatorio Etneo, Sezione de Catania. **Etna (Italy) Vigilancia e Monitoramento, Rede sísmica permanente**. Disponível em: <<https://www.ct.ingv.it/index.php/monitoraggio-e-sorveglianza/reti-di-monitoraggio/rete-sismica/rete-accelerometrica-permanente>>. Citado 3 vezes nas páginas 21, 22 e 23.
- PARIKH, R. et al. Understanding and using sensitivity, specificity and predictive values. **Indian journal of ophthalmology**, Wolters Kluwer–Medknow Publications, Mumbai, IN, v. 56, n. 1, p. 45, 2008. Citado na página 79.
- PARPOULA, C.; DROSOU, K.; KOUKOUVINOS, C. Large-scale statistical modelling via machine learning classifiers. **Journal of Statistics Applications & Probability**, New York, US, v. 2, n. 3, p. 203–222, 2013. Citado na página 56.
- PEARSON, K. Principal components analysis. **The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science**, Oxfordshire, UK, v. 6, n. 2, p. 559, 1901. Citado na página 65.
- PÉREZ, N. et al. E seismic: Towards an ecuadorian volcano seismic repository. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 396, p. 106855, 2020. Citado na página 58.
- PEZZO, E. D. et al. Discrimination of earthquakes and underwater explosions using neural networks. **Bulletin of the Seismological Society of America**, Seismological Society of America, California, US, v. 93, n. 1, p. 215–223, 2003. Citado 3 vezes nas páginas 16, 44 e 59.
- PINNEGAR, C. Polarization analysis and polarization filtering of three-component signals with the time—frequency s transform. **Geophysical Journal International**, Blackwell Publishing Ltd, Oxford, UK, v. 165, n. 2, p. 596–606, 2006. Citado na página 56.
- RABINER, L. R.; JUANG, B.-H. **Fundamentals of speech recognition**. Florida, US: Tsinghua University Press, 1999. Citado na página 68.
- RIGGELSEN, C.; OHRNBERGER, M.; SCHERBAUM, F. Dynamic bayesian networks for real-time classification of seismic signals. In: SPRINGER. **Knowledge Discovery in Databases: PKDD 2007: 11th European Conference on Principles and Practice of Knowledge Discovery in Databases, Warsaw, Poland, September 17-21, 2007. Proceedings 11**. Cham, CH, 2007. p. 565–572. Citado 2 vezes nas páginas 42 e 46.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, Washington-DC, US, v. 65, n. 6, p. 386, 1958. Citado na página 43.

- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **nature**, Nature Publishing Group, London, US, v. 323, n. 6088, p. 533–536, 1986. Citado na página 69.
- SACCOROTTI, G.; LOKMER, I. A review of seismic methods for monitoring and understanding active volcanoes. **Forecasting and planning for volcanic hazards, risks, and disasters**, Elsevier, Amsterdam, NL, p. 25–73, 2021. Citado 2 vezes nas páginas 15 e 41.
- SASSA, K. Micro-seismometric study on eruptions of the volcano aso:(part ii of the geophysical studies on the volcano aso). **Memoirs of the College of Science, Kyoto Imperial University. Series A**, College of Science, Kyoto Imperial University, Durham, US, v. 19, n. 1, p. 11–56, 1936. Citado na página 23.
- SCANDONE, R.; CASHMAN, K. V.; MALONE, S. D. Magma supply, magma ascent and the style of volcanic eruptions. **Earth and Planetary Science Letters**, Elsevier, Amsterdam, NL, v. 253, n. 3-4, p. 513–529, 2007. Citado na página 23.
- SCARPA, R.; TILLING, R. I. **Monitoring and mitigation of volcano hazards**. [S.l.]: Springer Science & Business Media, 2012. Citado 5 vezes nas páginas 19, 25, 34, 35 e 40.
- SCARPA, R.; TILLING, R. I.; CHOUET, B. New methods and future trends in seismological volcano monitoring. **Monitoring and mitigation of volcano hazards**, Springer, Cham, CH, p. 23–97, 1996. Citado 2 vezes nas páginas 15 e 25.
- SCARPA, R.; TILLING, R. I.; MCNUTT, S. Seismic monitoring and eruption forecasting of volcanoes: a review of the state-of-the-art and case histories. **Monitoring and mitigation of volcano hazards**, Springer, Cham, CH, p. 99–146, 1996. Citado na página 38.
- SCARPA, R.; TILLING, R. I.; SCARPA, R.; GASPARINI, P. A review of volcano geophysics and volcano-monitoring methods. **Monitoring and mitigation of volcano hazards**, Springer, Cham, CH, p. 3–22, 1996. Citado na página 15.
- SCARPETTA, S. et al. Automatic classification of seismic signals at mt. vesuvius volcano, italy, using neural networks. **Bulletin of the Seismological Society of America**, Seismological Society of America, California, US, v. 95, n. 1, p. 185–196, 2005. Citado 4 vezes nas páginas 16, 42, 44 e 59.
- SEIDL, D.; SCHICK, R.; RIUSCETTI, M. Volcanic tremors at etna: a model for hydraulic origin. **Bulletin volcanologique**, Springer, Cham, CH, v. 44, p. 43–56, 1981. Citado na página 27.
- Servicio Geológico Colombiano. **Generalidades - Volcán Galeras**. <<https://www2.sgc.gov.co/sgc/volcanes/VolcanGaleras/Paginas/generalidades-volcan-galeras.aspx>>. Fecha de acceso: 20 de julio de 2023. Citado 2 vezes nas páginas 19 e 20.
- SHANNON, C. E. Communication in the presence of noise. **Proceedings of the IRE**, IEEE, New Jersey, US, v. 37, n. 1, p. 10–21, 1949. Citado na página 62.
- SKANSI, S. **Introduction to Deep Learning: from logical calculus to artificial intelligence**. Cham, CH: Springer, 2018. Citado 2 vezes nas páginas 69 e 70.

- SONG, L.; KOLAR, M.; XING, E. Time-varying dynamic bayesian networks. **Advances in neural information processing systems**, Maryland, US, v. 22, 2009. Citado na página 46.
- SPAMPINATO, S.; LANGER, H.; MESSINA, A.; FALSAPERLA, S. Short-term detection of volcanic unrest at mt. etna by means of a multi-station warning system. **Scientific reports**, Nature Publishing Group, London, UK, v. 9, n. 1, p. 6506, 2019. Citado na página 42.
- SRIVASTAVA, N. et al. Dropout: a simple way to prevent neural networks from overfitting. **The journal of machine learning research**, JMLR. org, United States, v. 15, n. 1, p. 1929–1958, 2014. Citado na página 71.
- STÄHLER, S. C.; SIGLOCH, K. Fully probabilistic seismic source inversion–part 1: Efficient parameterisation. **Solid Earth**, Copernicus Publications, Göttingen, DE, v. 5, n. 2, p. 1055–1069, 2014. Citado na página 60.
- TAYLOR, K. M.; PROCOPIO, M. J.; YOUNG, C. J.; MEYER, F. G. Estimation of arrival times from seismic waves: a manifold-based approach. **Geophysical Journal International**, Blackwell Publishing Ltd, Oxford, UK, v. 185, n. 1, p. 435–452, 2011. Citado 2 vezes nas páginas 58 e 60.
- TILLING, R. The critical role of volcano monitoring in risk reduction. **Advances in Geosciences**, Copernicus Publications, Göttingen, DE, v. 14, p. 3–11, 2008. Citado na página 15.
- TITOS, M.; BUENO, A.; GARCIA, L.; BENITEZ, C. A deep neural networks approach to automatic recognition systems for volcano-seismic events. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, IEEE, New Jersey, US, v. 11, n. 5, p. 1533–1544, 2018. Citado na página 67.
- TITOS, M. et al. Detection and classification of continuous volcano-seismic signals with recurrent neural networks. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 57, n. 4, p. 1936–1948, 2018. Citado 2 vezes nas páginas 17 e 44.
- TITOS, M. et al. Detection and classification of continuous volcano-seismic signals with recurrent neural networks. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, New Jersey, US, v. 57, n. 4, p. 1936–1948, 2018. Citado 2 vezes nas páginas 44 e 64.
- TITOS, M. et al. Multi-station volcano-tectonic earthquake monitoring based on transfer learning. **Frontiers in Earth Science**, Frontiers, Lausanne, CH, v. 11, p. 1204832, 2023. Citado na página 42.
- UNGLERT, K.; JELLINEK, A. M. Principal component analysis for pattern recognition in volcano seismic spectra. In: **EGU General Assembly Conference Abstracts**. Prague, CZ: [s.n.], 2016. p. EPSC2016–16830. Citado na página 60.
- VAPNIK, V. **The nature of statistical learning theory**. Cham, CH: Springer science & business media, 1999. Citado 2 vezes nas páginas 43 e 65.
- VENEGAS, P. et al. Building machine learning models for long-period and volcano-tectonic event classification. In: IEEE. **2019 IEEE CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON)**. Santiago, CL,

2019. p. 1–6. Citado na página 46.

VENZKE, E.; BENNIS, K. L. **Etna (Italy) Lava flows, pyroclastic flows, Strombolian explosions, and ash plumes during February-June 2022**. 2022. Bulletin of the Global Volcanism Network, vol. 47, no. 7. Disponível em: <<https://doi.org/10.5479/si.GVP.BGVN202207-211060>>. Citado 2 vezes nas páginas 21 e 22.

VINCENT, P. et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. **Journal of machine learning research**, United States, v. 11, n. 12, 2010. Citado na página 72.

VISSER, I. Seven things to remember about hidden markov models: A tutorial on markovian models for time series. **Journal of Mathematical Psychology**, Elsevier, Amsterdam, NL, v. 55, n. 6, p. 403–415, 2011. Citado na página 46.

VOIGHT, B. The 1985 nevado del ruiz volcano catastrophe: anatomy and retrospection. **Journal of volcanology and geothermal research**, Elsevier, Amsterdam, NL, v. 44, n. 3-4, p. 349–386, 1990. Citado 2 vezes nas páginas 15 e 34.

WAN, H.; WANG, H.; SCOTNEY, B.; LIU, J. A novel gaussian mixture model for classification. In: IEEE. **2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)**. [s.l.], 2019. p. 3298–3303. Citado na página 45.

WANG, J.; TENG, T.-L. Artificial neural network-based seismic detector. **Bulletin of the Seismological Society of America**, The Seismological Society of America, California, US, v. 85, n. 1, p. 308–319, 1995. Citado na página 41.

WASIKOWSKI, M.; CHEN, X.-w. Combating the small sample class imbalance problem using feature selection. **IEEE Transactions on knowledge and data engineering**, IEEE, New Jersey, US, v. 22, n. 10, p. 1388–1400, 2009. Citado 2 vezes nas páginas 16 e 17.

WASSERMANN, J. Volcano seismology. In: **New manual of seismological observatory practice 2 (NMSOP-2)**. Potsdam, DE: Deutsches GeoForschungsZentrum GFZ, 2012. p. 1–77. Citado 4 vezes nas páginas 29, 30, 34 e 36.

WERBOS, P. J. **Análise da Estabilidade Transitória via Rede Neural ART-ARTMAP Fuzzy Euclidiana Modificada com Treinamento Continuado**. 1974. 906 f. Tese (Doutorado) — Universidade Harvard, Cambridge, US, 1974. Citado na página 44.

WHITE, R. A.; MILLER, A. D.; LYNCH, L.; POWER, J. Observations of hybrid seismic events at soufriere hills volcano, montserrat: July 1995 to september 1996. **Geophysical Research Letters**, Wiley Online Library, New Jersey, US, v. 25, n. 19, p. 3657–3660, 1998. Citado na página 29.

WILLIAMS, S. N.; CALVACHE, M. L. Emplacement and petrological evolution of the andesitic dome of galeras volcano, 1990–1992. **Journal of Volcanology and Geothermal Research**, Elsevier, Amsterdam, NL, v. 77, n. 1-4, p. 57–69, 1997. Citado na página 20.

YACOUBY, R.; AXMAN, D. Probabilistic extension of precision, recall, and f1 score for more thorough evaluation of classification models. In: **Proceedings of the first workshop on evaluation and comparison of NLP systems**. Orzens, CH: [s.n.], 2020. p. 79–91. Citado na

página 79.

YEGUAS, A. G.; ALMENDROS, J.; ABELLA, R.; IBÁÑEZ, J. Quantitative analysis of seismic wave propagation anomalies in azimuth and apparent slowness at deception island volcano (antarctica) using seismic arrays. **Geophysical Journal International**, Blackwell Publishing Ltd, Oxford, UK, v. 184, n. 2, p. 801–815, 2011. Citado na página 32.

YEUNG, D. S.; LI, J.-C.; NG, W. W.; CHAN, P. P. Mlpnn training via a multiobjective optimization of training error and stochastic sensitivity. **IEEE transactions on neural networks and learning systems**, IEEE, New Jersey, US, v. 27, n. 5, p. 978–992, 2015. Citado na página 74.

YIN, K. et al. Logan: Unpaired shape transform in latent overcomplete space. **ACM Transactions on Graphics (TOG)**, ACM New York, New York, US, v. 38, n. 6, p. 1–13, 2019. Citado na página 69.

ZUCCHINI, W.; MACDONALD, I. L. **Hidden Markov models for time series: an introduction using R**. Florida, US: Chapman and Hall/CRC, 2009. Citado na página 46.