



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

**MONITORAMENTO DO ÍNDICE DE VAZIOS EM UM MODELO DE  
BARRAGEM EM ESCALA DE LABORATÓRIO UTILIZANDO  
SÍSMICA PASSIVA E INTELIGÊNCIA ARTIFICIAL**

**RAFAEL MENDES JORGE**

**ORIENTADOR: ANDRÉ LUÍS BRASIL CAVALCANTE, PhD**

**DISSERTAÇÃO DE MESTRADO EM GEOTECNIA  
PUBLICAÇÃO G.DM –422/2025**

**BRASÍLIA-DF  
2025**

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

**MONITORAMENTO DO ÍNDICE DE VAZIOS EM UM MODELO DE  
BARRAGEM EM ESCALA DE LABORATÓRIO UTILIZANDO  
SÍSMICA PASSIVA E INTELIGÊNCIA ARTIFICIAL**

**RAFAEL MENDES JORGE**

**DISSERTAÇÃO DE MESTRADO SUBMETIDA AO DEPARTAMENTO DE  
ENGENHARIA CIVIL E AMBIENTAL DA UNIVERSIDADE DE BRASÍLIA COMO  
PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO TÍTULO DE  
MESTRE.**

**APROVADA POR:**

**ANDRÉ LUÍS BRASIL CAVALCANTE, PhD (ENC/UnB).  
(Orientador)**

**ANDRÉ PACHECO DE ASSIS, PhD (ENC/UnB)  
(Examinador interno)**

**LUAN CARLOS DE SENA MONTEIRO OZELIM, DSc (Senado Federal)  
(Examinador externo)**

Brasília/DF

Maio/2025

## FICHA CATALOGRÁFICA

JORGE, RAFAEL MENDES

Monitoramento do índice de vazios em um modelo de barragem em escala de laboratório utilizando sísmica passiva e inteligência artificial. 95p., 210 x 297 mm (ENC/FT/UnB, Mestrado, Geotecnica, 2025)

Dissertação de mestrado – Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Civil e Ambiental.

- |                          |                            |
|--------------------------|----------------------------|
| 1. Erosão interna        | 2. Inteligência artificial |
| 3. Monitoramento sísmico | 4. Barragens               |
| I. ENC/FT/UnB            | II. Mestrado               |

## REFERÊNCIA BIBLIOGRÁFICA

JORGE, R. M. (2025). Monitoramento do índice de vazios em um modelo de barragem em escala de laboratório utilizando sísmica passiva e inteligência artificial. Dissertação de Mestrado, Publicação PPG G.DM – 422/2025, Departamento de Engenharia Civil, Universidade de Brasília, Brasília, DF, 95 p.

## CESSÃO DE DIREITOS

NOME DO AUTOR: Rafael Mendes Jorge

TÍTULO DA DISSERTAÇÃO DE MESTRADO: Monitoramento do índice de vazios em um modelo de barragem em escala de laboratório utilizando sísmica passiva e inteligência artificial

GRAU/ANO: Mestre / 2025

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

Rafael Mendes Jorge  
Quadra 49, Casa 61  
Setor Leste  
72455-490, Gama, Distrito Federal/DF - Brasil.

## ***DEDICATÓRIA***

*À Deus  
e a todos que trabalharam para que hoje  
eu pudesse estar aqui*

## AGRADECIMENTOS

Agradeço primeiro à Deus, por todas as oportunidades, por ter preparado todo o caminho até essa conquista, pela força que Ele me deu para finalizar essa caminhada e por todas as pessoas que colocou no caminho para me auxiliar.

Agradeço à minha família, minhas tias Aurelina, Aucéia, minha prima Danielle pelo apoio e preocupação constantes e meu tio Adivan, pela ajuda na concepção das peças de madeira utilizadas no projeto. Agradeço minhas irmãs, Jéssica, Larissa, Emily e Milena, pelas conversas, pela cobrança, pelo incentivo e pelo apoio incondicional. Por fim agradeço meus pais, Adilson e Rosângela pela preocupação e incentivo em toda a dissertação, em especial meu pai, pelo apoio no laboratório (que incluíram visitas aos domingos para montagem dos sistemas de entrada e saída de água e dias até tarde montando peças para auxiliar a montagem dos experimentos) e pelas ideias para resolver todos os problemas no caminho. Amo vocês!

Agradeço à minha namorada Mariana, pelo apoio incondicional durante toda a dissertação, pelas noites até tarde no laboratório destorrrando, pesando, compactando material e ajustando as vazões quando não tínhamos pensado em todo o sistema de entrada de água. Agradeço pelas ideias e soluções para todos os problemas que surgiram no caminho, pelas discussões dos melhores caminhos para seguir em cada tomada de decisão, pela elaboração das imagens usadas na dissertação, por ter me ajudado a finalizar o texto e os slides e por ter me encorajado mesmo nos momentos que eu já não tinha ânimo para continuar. Sem você esse trabalho não teria acontecido. Te amo!

Agradeço ao seu Dorgival e dona Jailma, pela preocupação com o andamento do trabalho e pela ajuda durante a elaboração, seja nos dias de caminhada no parque para esfriar a mente, estimulados pela dona Jailma, ou na ajuda com a parte de eletrônica com o seu Dorgival. Muito obrigado pelo apoio e carinho!

Agradeço meu orientador e amigo, o professor André Brasil. Nos conhecemos a mais de 6 anos, mais ou menos no meio da minha graduação no início de 2019, quando eu cursei a disciplina de Geotecnia 2, e desde então o senhor confiou em mim e me apoiou em todos os projetos, que já somam 2 PIBICs, 1 TCC, 4 projetos de pesquisa, 1 consultoria e esse mestrado. Muito obrigado pela confiança, o senhor trouxe para mim a paixão que eu não tinha pelo curso que se tornou a minha profissão. Obrigado pelo apoio em todas as situações, pelos conselhos e pelas conversas.

Agradeço ao grupo de pesquisa Geofluxo, o qual eu tive a grande oportunidade de fazer parte por intermédio do professor André Brasil. Foi nele que eu aprendi a fazer pesquisa, a ver os problemas e pensar em soluções. Agradeço por todas as ideias e discussões que ajudaram no desenvolvimento dessa pesquisa, seja no dia a dia do laboratório ou nos seminários. Agradeço de forma especial à Manuelle, uma grande amiga que me apoiou com as ideias e revisões do texto e que vem nessa caminhada comigo desde o meu segundo PIBIC, que coincidiu com o tempo que estávamos desenvolvendo o projeto AINOÁ. Você me ensinou a essência da pesquisa pelos seus olhos, por meio do seu cuidado e zelo com todos os aspectos que permeiam esse processo de descoberta de novas soluções para os problemas do nosso dia a dia. Obrigado por todo o carinho! Agradeço também a todos que me ajudaram com conselhos, discussões e conversas seja sobre o tema ou para tornar os dias mais leves: Katherin, Mateus Bezerra, Patrícia, Ana Paola, Daniel Batista, Enzo e Jordana.

Agradeço aos meus companheiros de caminhada durante esse mestrado, minha turma de 2022, principalmente durante os primeiros semestres do curso com as disciplinas obrigatórias e optativas. Obrigado pelo apoio, pelas discussões e pelos finais de semana/dias até tarde estudando na UnB.

Por fim agradeço aos técnicos do laboratório de geotecnia da UnB, Saimo e Rogério. Em especial ao Rogério, pelas discussões sobre os melhores caminhos para seguir diante dos problemas que surgiram durante a compactação do material. Sua experiência prática com a argila utilizada foi essencial para a finalização da pesquisa, muito obrigado pelas ideias e dicas!

# MONITORAMENTO DO ÍNDICE DE VAZIOS EM UM MODELO DE BARRAGEM EM ESCALA DE LABORATÓRIO UTILIZANDO SÍSMICA PASSIVA E INTELIGÊNCIA ARTIFICIAL

## RESUMO

As barragens desempenham um papel essencial no contexto mundial por possuírem várias aplicações voltadas à manutenção dos recursos hídricos, tais como: controle de cheias, armazenamento de água para abastecimento público e irrigação, além da geração de energia elétrica e retenção de rejeitos de mineração. No entanto, seu alto Dano Potencial Associado gera riscos a populações próximas, e no Brasil, a ligação com setores econômicos-chave, como agricultura e mineração, intensifica a necessidade de monitoramento contínuo. Segundo o Comitê Internacional de Grandes Barragens, a maioria das barragens no mundo é de terra, sendo a erosão interna (*piping*) uma das principais causas de ruptura. No Brasil, os registros da Agência Nacional de Águas não detalham adequadamente as causas de rompimentos, dificultando a comparação com estatísticas globais. A detecção precoce do *piping* é complexa com métodos tradicionais, mas técnicas geofísicas, como o monitoramento sísmico, têm se destacado na literatura como alternativas complementares para identificar descontinuidades de forma qualitativa. Contudo, medidas quantitativas são essenciais para tomadas de decisão na engenharia geotécnica. Diante desse contexto, o presente trabalho fundamentou-se no uso de monitoramento sísmico para estabelecer uma relação com um parâmetro intermediário (índice de vazios) relacionado à ocorrência de *piping* em um modelo de barragem em escala de laboratório, permitindo obter uma medida quantitativa do estado do modelo no tempo. Inicialmente, cenários estáticos definiram a assinatura sísmica do material sob diferentes condições de compactação. Em seguida, um cenário dinâmico acompanhou a variação temporal do parâmetro intermediário. Modelos de Inteligência Artificial (IA) de classificação e regressão, treinados com os dados estáticos, foram aplicados para prever a variação do índice de vazios no cenário dinâmico. Os resultados mostraram que os modelos de IA diferenciaram bem os cenários estáticos. No cenário dinâmico, a previsão da variação do parâmetro intermediário não teve correspondência com as observações físicas do modelo.

Palavras-chaves: barragens, erosão interna (*piping*), monitoramento sísmico, inteligência artificial.

**VOID RATIO MONITORING IN A LABORATORY-SCALE DAM MODEL USING  
PASSIVE SEISMICS AND ARTIFICIAL INTELLIGENCE**

**ABSTRACT**

*Dams play an essential role globally due to their various applications in electricity generation, retention of mining waste and water resources management, such as flood control, water storage for public supply and irrigation. However, their high Associated Potential Damage poses risks to nearby populations, and in Brazil, their connection to key economic sectors like agriculture and mining intensifies the need for continuous monitoring. According to the International Commission on Large Dams, most dams worldwide are earth dams, with internal erosion (piping) being one of the leading causes of failure. In Brazil, records from the Agência Nacional de Águas e Saneamento Básico do not adequately detail the causes of dam failures, making comparisons with global statistics difficult. Early detection of piping is complex with traditional methods, but geophysical techniques, such as seismic monitoring, have been highlighted in the literature as complementary alternatives for qualitatively identifying discontinuities. However, quantitative measurements are essential for decision-making in geotechnical engineering. In this context, the present study focused on using seismic monitoring to establish a relationship with an intermediate parameter (void ratio) linked to the occurrence of piping in a laboratory-scale dam model, allowing for a quantitative measure of the model's state over time. Initially, static scenarios defined the seismic signature of the material under different compaction conditions. Subsequently, a dynamic scenario monitored the temporal variation of the intermediate parameter. Artificial Intelligence (AI) models for classification and regression, trained with the static data, were applied to predict the variation of the void ratio in the dynamic scenario. The results showed that the AI models differentiated the static scenarios well. In the dynamic scenario, the prediction of the intermediate parameter's variation didn't correspond with the physical observations of the model.*

*Keywords: dams, internal erosion (piping), seismic monitoring, artificial intelligence.*

## SUMÁRIO

1.	INTRODUÇÃO .....	1
1.1.	OBJETIVOS.....	2
1.2.	ESTRUTURA DA DISSERTAÇÃO .....	3
2.	REFERENCIAL TEÓRICO.....	4
2.1.	EROSÃO INTERNA EM BARRAGENS DE TERRA .....	4
2.2.	MONITORAMENTO E DETECÇÃO DE EROSÃO INTERNA.....	7
2.3.	MODELOS REDUZIDOS DE BARRAGEM PARA MONITORAMENTO DE <i>PIPING</i> EM LABORATÓRIO.....	12
2.4.	PREPARAÇÃO DE DADOS SÍSMICOS PARA DETECÇÃO DE ANOMALIAS	
	17	
2.5.	INTELIGÊNCIA ARTFICIAL PARA DETECÇÃO DE ANOMALIAS .....	19
3.	MATERIAIS E METODOLOGIA.....	27
3.1.	MATERIAIS.....	27
3.1.1.	CARACTERIZAÇÃO DOS MATERIAIS GEOTÉCNICOS .....	27
3.1.2.	EQUIPAMENTO EXPERIMENTAL .....	30
3.1.3.	INSTRUMENTAÇÃO .....	31
3.1.4.	EXTRAÇÃO DOS ATRIBUTOS DAS ONDAS.....	32
3.2.	METODOLOGIA .....	33
3.2.1.	DIMENSÕES E MONTAGEM DO MODELO EM LABORATÓRIO .....	37
3.2.2.	CONFIGURAÇÃO DO ENSAIO.....	39
3.2.3.	MODELOS DE IA E ANÁLISE DOS RESULTADOS.....	40
4.	RESULTADOS E DISCUSSÕES .....	42
4.1.	DEFINIÇÃO DO PARÂMETRO INTERMEDIÁRIO.....	42
4.1.1.	CENÁRIO 1 .....	43
4.1.2.	CENÁRIO 2 .....	45
4.1.3.	CENÁRIO 3 .....	46

4.2. MONTAGEM E MONITORAMENTO DOS CENÁRIOS ESTÁTICOS .....	48
4.2.1. CENÁRIO 1 .....	48
4.2.2. CENÁRIO 2 .....	52
4.2.3. CENÁRIO 3 .....	56
4.2.4. CENÁRIO 4 .....	59
4.2.5. CENÁRIO 5 .....	63
4.3. ALGORITMO DE IDENTIFICAÇÃO DOS CENÁRIOS ESTÁTICOS .....	67
4.4. MONITORAMENTO DO CENÁRIO DINÂMICO .....	70
4.5. MEDIDA TRANSIENTE DO ÍNDICE DE VAZIOS.....	74
5. CONCLUSÕES E SUGESTÕES PARA PESQUISAS FUTURAS.....	78
REFERÊNCIAS BIBLIOGRÁFICAS.....	80
1. APÊNDICE A – ATRIBUTOS EXTRAÍDOS .....	86
2. APÊNDICE B – MONITORAMENTO DOS CENÁRIOS .....	93

## LISTA DE FIGURAS

Figura 1 – Árvore de eventos representando as várias fases que precedem uma falha por erosão interna pelo aterro (Modificado de Fell & Fry, 2007).....	5
Figura 2 – Principais mecanismos de iniciação da erosão interna (Modificado de Robbins & Griffths, 2018) .....	7
Figura 3 – Técnicas de monitoramento acústico utilizada para o monitoramento de materiais/estruturas geológicas: (a) Método sônico; (b) Métodos sísmicos/acústicos (Modificado de Hardy Jr., 2003). .....	9
Figura 4 – Estrutura construída para simular o <i>piping</i> em laboratório: (a) seção transversal após a remoção da barra; (b) resultado da simulação (Modificado de Fisher <i>et al.</i> , 2017a). .....	13
Figura 5 – Modelo em escala de laboratório para simulação de <i>piping</i> : (a) vista frontal e; (b) seção transversal; (c) resultado da erosão após 0,5h, 1,5h, 2,5h, 3,5h e 5h após iniciação do <i>piping</i> (Modificado de Planès <i>et al.</i> , 2016). .....	14
Figura 6 – Evolução da ruptura do modelo de barragem em larga escala (Hanson <i>et al.</i> , 2010). .....	15
Figura 7 – Modelo de barragem para simulação de <i>piping</i> : (a) seção transversal; (b) resultado da erosão (Modificado de Hickey <i>et al.</i> , 2009). .....	16
Figura 8 – Localização do Campo Experimental do Programa de Pós-Graduação em Geotecnia (modificado de Google Earth, 2025).....	28
Figura 9 – Perfil estratigráfico do solo no Campo Experimental do PPGG/UnB (Modificado de Rebolledo <i>et al.</i> , 2019). .....	28
Figura 10 – Curva granulométrica da argila do Campo Experimental do PPGG/UnB (Lopes, 2019).....	29
Figura 11 – Curvas de compactação do solo do Campo Experimental do PPGG/UnB com ajuste polinomial de grau 3 (Collantes, 2022; Lopes, 2019; Neves, 2025; Silva <i>et al.</i> , 2024). .....	30
Figura 12 – Dimensões da caixa de vidro tendo por base blocos de concreto. .....	31
Figura 13 – Sistema <i>Raspberry Shake</i> com três geofones (RS3D). .....	31
Figura 14 – Fluxograma metodológico realizado nesta pesquisa. .....	34
Figura 15 – Condições de contorno e inicial de cada um dos cenários estáticos. .....	35
Figura 16 – Condições de contorno e condição inicial/final do cenário dinâmico. .....	36
Figura 17 – Dimensões do modelo de barragem.....	37

Figura 18 – Esquema de montagem e compactação das camadas do modelo de barragem: (a) primeira camada, com o sulco para inserção do tubo; (b) segunda camada; (c) terceira camada; (d) quarta camada e; (e) quinta camada.....	39
Figura 19 – Sistema de monitoramento para os cenários estáticos e dinâmicos da barragem em escala de laboratório.....	40
Figura 20 – Montagem dos 3 cenários de monitoramento da Etapa 1.....	43
Figura 21 – Espectrograma de frequência do sensor R7D9F: (a) componente EHE; (b) componente EHN; (c) componente EHZ.....	44
Figura 22 – Conteúdo de frequência do sensor R7D9F: (a) componente EHE; (b) componente EHN; (c) componente EHZ.....	44
Figura 23 – Espectrogramas de frequência do sensor R17F9: (a) componente EHE; (b) componente EHN; (c) componente EHZ.....	45
Figura 24 – Conteúdo de frequência do sensor R17F9: (a) componente EHE; (b) componente EHN; (c) componente EHZ.....	46
Figura 25 – Espectrogramas de frequência do sensor RA0F7: (a) componente EHE; (b) componente EHN; (c) componente EHZ.....	47
Figura 26 – Conteúdo de frequência do sensor RA0F7: (a) componente EHE; (b) componente EHN; (c) componente EHZ.....	48
Figura 27 – Vista frontal das camadas durante o processo de compactação cenário 1.....	50
Figura 28 – Barragem montada cenário 1.....	50
Figura 29 – Sismograma para o Cenário 1.....	51
Figura 30 – Espectrograma para o Cenário 1 com os seguintes parâmetros: <i>frame size</i> (comprimento da janela de análise) = 1024 e <i>hop length</i> (deslocamento da janela de análise) = 512.....	51
Figura 31 – Vista frontal das camadas durante o processo de compactação cenário 2.....	53
Figura 32 – Barragem montada cenário 2.....	54
Figura 33 – Sismograma para o Cenário 2.....	55
Figura 34 – Espectrograma para o Cenário 2 com os seguintes parâmetros: <i>frame size</i> (comprimento da janela de análise) = 1024 e <i>hop length</i> (deslocamento da janela de análise) = 512.....	55
Figura 35 – Vista frontal das camadas durante o processo de compactação cenário 3.....	57
Figura 36 – Barragem montada cenário 3.....	57
Figura 37 – Sismograma para o Cenário 3.....	58

Figura 38 – Espectrograma para o Cenário 3 com os seguintes parâmetros: <i>frame size</i> (comprimento da janela de análise) = 1024 e <i>hop length</i> (deslocamento da janela de análise) = 512.....	59
Figura 39 –Vista frontal das camadas durante o processo de compactação cenário 4.....	61
Figura 40 –Barragem montada cenário 4.....	61
Figura 41 – Sismograma para o Cenário 4.....	62
Figura 42 – Espectrograma para o Cenário 4 com os seguintes parâmetros: <i>frame size</i> (comprimento da janela de análise) = 1024 e <i>hop length</i> (deslocamento da janela de análise) = 512.....	63
Figura 43 –Vista frontal das camadas durante o processo de compactação cenário 5.....	65
Figura 44 –Barragem montada do cenário 5 e do cenário dinâmico.....	65
Figura 45 – Sismograma para o Cenário 5.....	66
Figura 46 – Espectrograma para o Cenário 5 com os seguintes parâmetros: <i>frame size</i> (comprimento da janela de análise) = 1024 e <i>hop length</i> (deslocamento da janela de análise) = 512.....	67
Figura 47 – Matriz de confusão com a validação cruzada para os dados de treino utilizando o modelo SVM.....	69
Figura 48 – Matriz de confusão para os dados de teste utilizando o modelo SVC.....	70
Figura 49 – Início do monitoramento: (a) antes da retirada do tubo metálico e; (b) após a retirada do tubo.....	71
Figura 50 – Evolução do <i>piping</i> durante duas semanas de monitoramento: (a) primeiro dia; (b) segundo dia; (c) terceiro dia; (d) quarto dia; (e) quinto dia; (f) oitavo dia; (g) décimo dia; (h) décimo primeiro dia; (i) décimo segundo dia; (j) décimo quinto dia.....	74
Figura 51 – Previsões do modelo SVM durante o monitoramento dinâmico e média móvel dos valores previstos.....	75
Figura 52 – Previsões do modelo de regressão <i>Support Vector Regressor</i> durante o monitoramento do cenário dinâmico e média móvel dos valores previstos.....	75
Figura 1.A – Representação do Spectral Centroid com os seguintes parâmetros: tamanho do quadro de análise ( <i>frame size</i> ) = 1024 e deslocamento da janela ( <i>hop length</i> ) = 512, aplicados aos cenários estáticos: (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4 e (e) cenário 5..	87
Figura 2.B – Representação do Spectral Bandwidth com os seguintes parâmetros: tamanho do quadro de análise ( <i>frame size</i> ) = 1024 e deslocamento da janela ( <i>hop length</i> ) = 512, aplicados aos cenários estáticos: (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4 e (e) cenário 5..	88

Figura 3.A – Representação do Band Energy Ratio (BER) normalizado com os seguintes parâmetros: tamanho do quadro de análise (frame size) = 1024 e deslocamento da janela (hop length) = 512, aplicados aos cenários estáticos: (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4 e (e) cenário 5.....	90
Figura 4.A – Representação do Zero Crossing Rate (ZCR) com os seguintes parâmetros: tamanho do quadro de análise (frame size) = 1024 e deslocamento da janela (hop length) = 512, aplicados aos cenários estáticos: (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4 e (e) cenário 5.....	91
Figura 5.A – Representação do Spectral Centroid para o Cenário dinâmico, considerando 10 dias de monitoramento com os seguintes parâmetros: frame size (comprimento da janela de análise) = 1024 e hop length (deslocamento da janela de análise) = 512.....	91
Figura 6.A – Representação do Spectral Bandwidth para o Cenário dinâmico, considerando 10 dias de monitoramento com os seguintes parâmetros: frame size (comprimento da janela de análise) = 1024 e hop length (deslocamento da janela de análise) = 512.....	92
Figura 7.A – Representação do Band Energy Ratio (BER) normalizado para o Cenário dinâmico, considerando 10 dias de monitoramento com os seguintes parâmetros: frame size (comprimento da janela de análise) = 1024 e hop length (deslocamento da janela de análise) = 512.....	92
Figura 8.A – Representação do Zero Crossing Rate (ZCR) para o Cenário dinâmico, considerando 10 dias de monitoramento com os seguintes parâmetros: frame size (comprimento da janela de análise) = 1024 e hop length (deslocamento da janela de análise) = 512.....	92
Figura 1.B – Início do monitoramento do Cenário 1.....	93
Figura 2.B – Início do monitoramento do Cenário 2.....	93
Figura 3.B – Início do monitoramento do Cenário 3.....	94
Figura 4.B – Início do monitoramento do Cenário 4.....	94
Figura 5.B – Início do monitoramento do Cenário 5.....	95

## LISTA DE TABELAS

Tabela 1 - Condição inicial dos cenários estáticos e dinâmico. ....	36
Tabela 2 – Características dos materiais para determinação do parâmetro intermediário. ....	42
Tabela 3 – Média e desvio padrão dos atributos extraídos dos dados do Cenário 1. ....	52
Tabela 4 – Média e desvio padrão dos atributos extraídos dos dados do Cenário 2. ....	55
Tabela 5 – Média e desvio padrão dos atributos extraídos dos dados do Cenário 3. ....	59
Tabela 6 – Média e desvio padrão dos atributos extraídos dos dados do Cenário 4. ....	63
Tabela 7 – Média e desvio padrão dos atributos extraídos dos dados do Cenário 5. ....	67
Tabela 8 – Resumo da acurácia dos algoritmos de classificação e regressão avaliados para os dados de teste e treinamento.....	68
Tabela 9 – Métricas de desempenho do algoritmo SVM nos dados de treinamento com validação cruzada. ....	69
Tabela 10 – Métricas de desempenho do algoritmo SVC nos dados de teste. ....	70
Tabela 11 – Cálculo da variação do índice de vazios para a alteração no diâmetro do tubo simulando o desenvolvimento de <i>piping</i> no barramento.....	76

## 1. INTRODUÇÃO

Dada a importância socioeconômica que as barragens de terra representam na infraestrutura hídrica global, a garantia da segurança e integridade estrutural dessas obras a longo prazo é fundamental. Essas estruturas não estão isentas de riscos, e diversos modos de falha podem comprometer sua estabilidade e levar a consequências potencialmente catastróficas para as populações e o meio ambiente a jusante.

Segundo dados do cadastro mundial de barragens do Comitê Internacional de Grandes Barragens (ICOLD, 2020), 47% das barragens cadastradas têm como finalidade principal armazenar água para irrigação e 67% são barragens de terra. As grandes barragens são aquelas com altura mínima de 15 m e cujo reservatório possui uma capacidade maior que 3 milhões de metros cúbicos. No Brasil, esses dados constam no cadastro de barragens, que é a base da Política Nacional de Segurança de Barragens (PNSB). Desde sua criação em 2010, por meio da Lei Federal nº 12.334, até 2019, existem 19.388 barragens cadastradas, sendo 56% barragens de terra (ANA, 2019). A PNSB tem como objetivo garantir o cumprimento das medidas de segurança de barragens e reduzir o risco de acidentes. As barragens que se submetem à essa política são as grandes barragens cujo Dano Potencial Associado (DPA) é médio ou alto.

Segundo a estatística geral de modos de ruptura de grandes barragens de terra, apresentada no estudo de Foster *et al.* (2000), que analisou a estatística de acidentes de mais de 11.000 barragens, os modos de ruptura mais comuns são *piping* e galgamento. O estudo se concentrou especificamente em barragens de aterro, apresentando estatísticas que frequentemente atribuem uma proporção maior de falhas à erosão interna (*piping*), responsável por cerca de 46% a 48% das rupturas de barragens de aterro, tornando-a a principal causa ou uma causa de importância comparável ao galgamento, responsável por aproximadamente 40% a 46% das rupturas. Destes, o *piping* é o mais preocupante pois, por ser um processo de erosão interna. A análise de incidentes e falhas ocorridas em barragens mostra que os primeiros sinais da ocorrência deste fenômeno só podem ser observados durante a fase de progressão, quando a conexão entre jusante e montante já está bem desenvolvida. Nesta fase medidas de remediação se tornam mais caras e o risco de perda de vidas humanas é maior.

No Brasil, a disponibilidade de dados detalhados sobre as causas dos acidentes e incidentes é inconsistente ao longo da série histórica dos Relatórios de Segurança de Barragens (RSB), publicados anualmente pela Agência Nacional de Águas e Saneamento Básico (ANA). O galgamento se destaca nos dados de 2023, sendo responsável por 36% dos acidentes. A associação frequente de picos de eventos adversos com períodos de chuvas intensas e relatos

de transbordamento reforça a importância do galgamento como um modo de falha relevante no Brasil. Muitos dos casos de ruptura reportados no decorrer dos anos consta como causas desconhecidas. A persistência desta categoria ao longo dos anos é um fator limitante significativo, o que indica dificuldades na investigação das causas raízes dos eventos ou falhas no processo de reporte dessas informações ao Sistema Nacional de Informações sobre Segurança de Barragens (SNISB).

A utilização de métodos geofísicos para o monitoramento de barragens tem sido uma alternativa cada vez mais explorada na literatura para estudar o fenômeno de *piping*. Estes métodos, por serem não-destrutivos, possuem a vantagem de serem facilmente aplicados em barragens em operação, permitindo um monitoramento contínuo e a possibilidade de exploração de tecnologias como a Internet das Coisas (em inglês, *Internet of Things* – IOT) e Inteligência Artificial (IA). Porém muitos dos trabalhos que utilizaram monitoramento sísmico ou acústico para estudar o desenvolvimento de *piping* em modelos reduzidos de laboratório fazem uso de análise qualitativa, estudando os efeitos que o processo de iniciação desse fenômeno causa nas ondas monitoradas.

Neste cenário, o presente trabalho pretende utilizar o monitoramento sísmico do ruído ambiental para buscar uma medida de engenharia transiente, representada pelo índice de vazios, que estabeleça uma relação direta entre o processo de desenvolvimento de *piping* em uma simulação em laboratório e as alterações observadas nos dados monitorados.

## 1.1. OBJETIVOS

Obter uma medida transiente da variação de um parâmetro intermediário, que esteja relacionado ao processo de desenvolvimento de *piping* em um modelo em escala de laboratório, com o uso de monitoramento sísmico e inteligência artificial (IA). Para atingir este objetivo geral, propõe-se os seguintes objetivos específicos:

- Definir um parâmetro intermediário que esteja relacionado ao processo de desenvolvimento de *piping* e cuja variação é perceptível aos sensores utilizados;
- Simular cenários estáticos de *piping* com diferentes configurações do parâmetro escolhido e condições de contorno similares para monitorar a resposta do sensor em cada configuração em um modelo de barragem em escala de laboratório;
- Adaptar um algoritmo de IA para prever a variável escolhida em função dos resultados do monitoramento;

- Simular um cenário dinâmico de fluxo com variação do parâmetro escolhido e monitorar a mudança temporal da resposta do sensor às alterações ocorridas no modelo em escala de laboratório durante o desenvolvimento do *piping*;
- Analisar a medida transiente do parâmetro escolhido durante o cenário dinâmico, obtida utilizando o algoritmo de IA calibrado para as condições estáticas.

## 1.2. ESTRUTURA DA DISSERTAÇÃO

Esta dissertação está subdividida em cinco capítulos, seções e itens. O Capítulo 1 apresenta a introdução, com os principais aspectos que motivam o presente estudo, destacando a importância das barragens principalmente no contexto econômico mundial e a justificativa da pesquisa, contemplando por fim os objetivos do estudo.

O Capítulo 2 refere-se o embasamento teórico necessário para o estudo desenvolvido. Para isso, possui cinco seções que contemplam o desenvolvimento de erosão interna em barragens de terra, os métodos de detecção desse fenômeno utilizando sísmica passiva, focando ainda em estudos que utilizaram este método em modelos reduzidos de barragem. Em seguida são apresentadas as metodologias de análise de dados e o problema da identificação de anomalias utilizando algoritmos de inteligência artificial.

O Capítulo 3 detalha os materiais utilizados, com destaque à região de onde foi extraído o material e suas características. Em seguida é apresentada a metodologia utilizada para construção, simulação, monitoramento e análise do desenvolvimento de *piping* em um modelo em escala de laboratório.

O Capítulo 4 apresenta o processo de construção e monitoramento dos cenários em laboratório. Em seguida são apresentados os resultados do monitoramento dos cenários estáticos, com a análise da diferenciação dos cenários feita pelo algoritmo de Inteligência Artificial adaptado. Por fim são apresentados os resultados do monitoramento do cenário dinâmico e a análise do índice de vazios transiente.

O Capítulo 5 discute as principais conclusões do estudo, com destaque aos resultados do monitoramento dinâmico e as sugestões para pesquisas futuras, com o objetivo de tornar o estudo proposto no presente trabalho mais robusto e aplicável em situações reais.

Ao final do trabalho são apresentadas as referências utilizadas.

## 2. REFERENCIAL TEÓRICO

O presente capítulo apresenta o embasamento teórico necessário para o estudo desenvolvido, iniciando com os princípios norteadores para o desenvolvimento de erosão interna em barragens de terra, explorando os tipos conhecidos na literatura, as formas como estes mecanismos de ruptura se desenvolvem e como as propriedades do solo mudam nessas situações. Em seguida é abordado o uso de sísmica passiva como método de monitoramento de barragens e detecção de piping, sendo explorada a sua aplicação na literatura e as tecnologias comumente utilizadas. A aplicação desta metodologia em modelos reduzidos de barragem é explorada na sequência, com destaque às características dos modelos construídos e a forma de indução do *piping*. Por fim são apresentadas as metodologias de análise de dados para detecção de anomalia, explicando os atributos extraídos das ondas monitoradas para inserção nos modelos de Inteligência Artificial. Por fim é discutido o problema de detecção de anomalias usando IA e são destacados os modelos mais utilizados na literatura e seu funcionamento.

### 2.1. EROSÃO INTERNA EM BARRAGENS DE TERRA

Fundamentalmente, a erosão interna em barragens de terra ocorre quando, durante o fluxo da água no corpo do barramento, as partículas de solo são desagregadas e transportadas. Em comparação com outros mecanismos de ruptura de barragens, esse é particularmente perigoso por comprometer a integridade da estrutura de forma muitas vezes indetectável até que o mecanismo esteja bem desenvolvido (Robbins & Griffiths, 2018).

A primeira condição para que haja erosão interna é o carreamento das partículas. Bonelli (2013) diferencia três classes de solos vulneráveis à erosão interna. Na primeira classe estão os solos não plásticos, como as areias e siltes, que são facilmente erodidos mas tendem a colapsar quando saturados, não permitindo que uma abertura se mantenha. Na segunda classe estão os solos plásticos, como as argilas, que são mais resistentes à erosão em função da coesão entre as partículas. Essa mesma coesão permite que haja a formação de fissuras, mesmo quando saturado, e carreamento das partículas quando as forças de percolação são grandes o suficiente para vencer a forças de contato entre as partículas. Na terceira classe de solo estão as argilas dispersivas, que diferem das argilas plásticas em sua mineralogia. Neste tipo de solo a erosão será iniciada por fraturas sob pequenos gradientes hidráulicos. Se tratando de modelos de barragem em laboratório, a experiência corrobora com as observações dos autores, nos solos da primeira classe a reprodução dos mecanismos de erosão interna, mais especificamente na forma de *piping*, são difíceis de reproduzir, em função do colapso do solo quando saturado.

O processo de erosão interna em uma barragem depende de uma série de fatores, por isso uma visão sistemática do problema é importante para visualizar as diversas variáveis que estão relacionadas com as várias fases de seu desenvolvimento. A Figura 1 apresenta uma árvore de eventos das várias fases do desenvolvimento da erosão interna. Tipicamente na literatura a iniciação da erosão, seja por erosão regressiva, fuga concentrada, sufusão ou erosão de contato, é descrita como o princípio da erosão interna em barragens. Fell & Fry (2007) indicam que a consideração do carregamento e da localização onde há o início da erosão são importantes condicionantes da iniciação. Em relação ao carregamento ao qual a barragem está submetida, os autores indicam que eventos de cheia extremamente raros têm pouca influência na probabilidade anual de falha por erosão interna, os eventos mais relevantes têm um tempo de recorrência de até 100 anos. Os sismos também têm um papel importante, uma vez que falhas causadas por terremotos contribuem significativamente para a frequência de rupturas observadas em barragens. Muitos casos de erosão interna também estão relacionados com o local onde o processo é iniciado, que comumente ocorre em locais fissuras causadas por recalque diferencial de estruturas internas da barragem ou no contato entre a fundação e o núcleo.

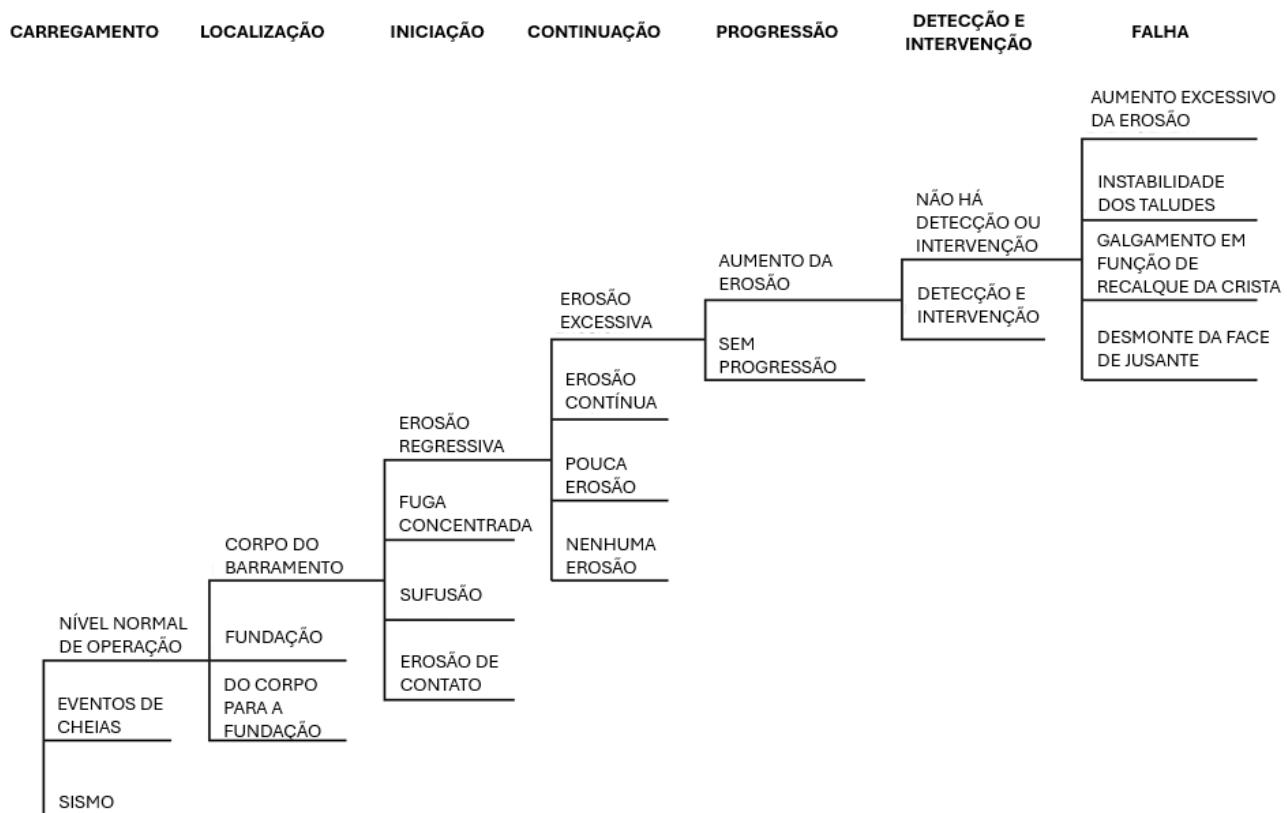


Figura 1 – Árvore de eventos representando as várias fases que precedem uma falha por erosão interna pelo aterro (Modificado de Fell & Fry, 2007).

A depender do tipo de processo que caracteriza a iniciação do *piping*, este pode ser distinguido por quatro diferentes mecanismos (Figura 2):

- I. **Erosão regressiva:** ocorre principalmente na fundação, podendo também se desenvolver no aterro. O processo de erosão se inicia em uma superfície livre no lado de jusante quando há a ocorrência de gradientes hidráulicos altos, que causam a erosão das partículas carregando-as para cima e progredindo pela fundação da barragem. Para isso acontecer, o material erodido deve ter a capacidade de formar um tubo (*pipe*), dando origem ao processo denominado *piping*. A presença desse tipo de erosão é muitas vezes caracterizada pelo aparecimento de borbulhamentos, comumente denominados *sand boils* (Bonelli, 2013).
- II. **Erosão por fuga concentrada:** ocorre quando há a formação de uma rachadura, que pode ser originada por vários fatores: fratura hidráulica causada por recalque diferencial durante a construção ou operação da barragem, colapso de regiões mal compactadas (comum nas proximidades com estruturas internas das barragens) ou a ação de animais, que também pode contribuir com a ocorrência desse tipo de erosão. A progressão desse tipo de erosão não ocorre caso o solo não consiga sustentar a rachadura ou haja mecanismos que evitam a evolução da erosão (Bonelli, 2013).
- III. **Erosão por instabilidade interna:** ocorre quando a percolação é capaz de erodir partículas finas em uma matriz de partículas mais grossas, podendo ser subdividido em sufusão (erosão sem mudança no volume) ou sufosão (erosão com mudança de volume) (Robbins & Griffiths, 2018).
- IV. **Erosão de contato:** ocorre no contato de material mais grosso com outro mais fino, o fluxo paralelo ao contato com o material mais grosso carrega as partículas finas, provocando a erosão (Bonelli, 2013).

Após a iniciação, a evolução da erosão interna ocorre por meio de três processos que culminam com a falha da estrutura:

- I. **Continuação da erosão:** Uma vez iniciada, a erosão prossegue se o fluxo de água for capaz de continuar a destacar e transportar partículas e se não houver um impedimento eficaz a jusante (como um filtro bem projetado) que retenha as partículas erodidas. A depender da estrutura interna do barramento, a abertura inicial pode ser mantida ou alargada.

- II. **Progressão:** A zona de erosão avança progressivamente através do corpo da barragem ou da fundação. Esta fase culmina com a formação de um conduto contínuo que conecta o reservatório à região de jusante.
  - III. **Falha:** Após o estabelecimento do conduto, o fluxo concentrado através dele aumenta significativamente. O aumento da velocidade do fluxo intensifica a erosão das paredes, causando seu rápido alargamento. Isso pode levar ao colapso do material e da estrutura do barramento pela instabilidade do talude de jusante ou por galgamento, em função do recalque da crista.

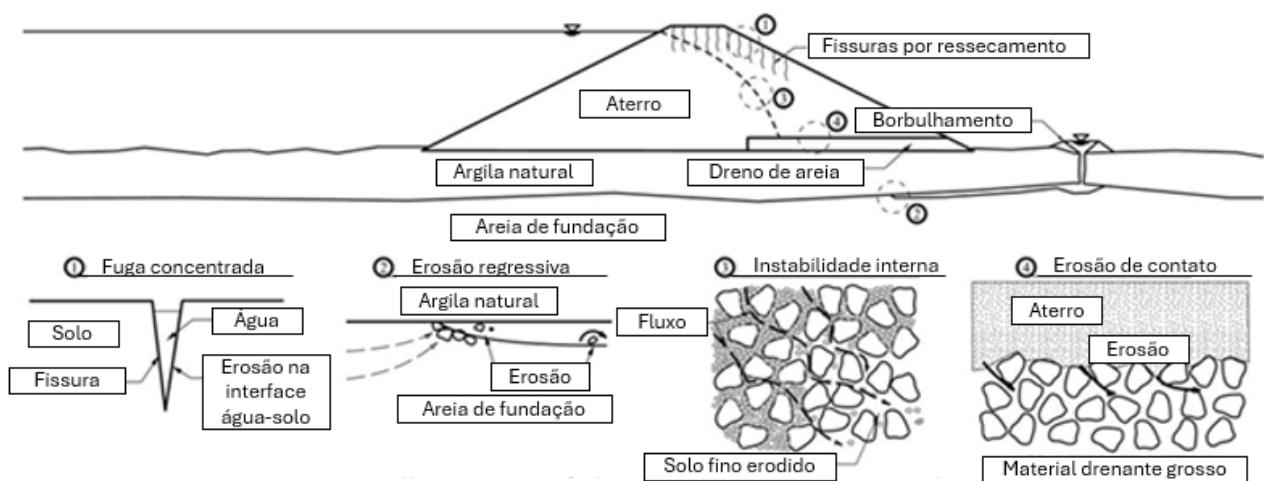


Figura 2 – Principais mecanismos de iniciação da erosão interna (Modificado de Robbins & Griffiths, 2018)

Ao remover partículas finas do corpo do barramento a erosão interna provoca alterações fundamentais nas propriedades físicas do solo remanescente. Essas alterações, principalmente no índice de vazios, porosidade e distribuição granulométrica, são a base para as mudanças subsequentes nas propriedades hidráulicas e mecânicas.

## 2.2. MONITORAMENTO E DETECÇÃO DE EROSÃO INTERNA

Tradicionalmente o monitoramento do desempenho da estrutura de um barramento face às possíveis mudanças, seja elas no seu comportamento hidráulico ou mecânico, é feito com o uso de instrumentos como medidores de nível d'água, piezômetros, células de tensão total, medidores de deslocamentos, medidores de recalques, inclinômetros, medidores de vazão, entre outros. Cruz (1996), em seu livro que reúne uma vasta experiência sobre a construção de barragens no Brasil destaca que, “considerando que acidentes de barragens de terra estão

associados a erosões externas (normalmente não auscultadas por instrumentos) , ou a erosões internas, ou a instabilidades, e que a maioria das obras não dispõe de dispositivos para medição das vazões de percolação, e que os instrumentos estão associados a ‘volumes de influência’ limitados, que muitas vezes não contêm os locais mais críticos para segurança, fica um tanto reduzida a probabilidade de detectar por meio da instrumentação, de forma incipiente, a ocorrência de condições adversas à segurança”. Apesar da grande vantagem da possibilidade de fornecer medidas diretas do comportamento do barramento, o autor destaca que, em face de uma série de limitações associadas à cobertura espacial limitada, a instrumentação tradicional deve ser acompanhada de um plano eficiente de inspeções visuais e de outros sistemas de observação.

Os métodos geofísicos têm o potencial de oferecer uma forma mais econômica e facilmente aplicável de acompanhar o comportamento das barragens durante sua vida útil de forma não destrutiva. Neste cenário os métodos geofísicos surgem como um método complementar ao tradicionalmente utilizado na engenharia de barragens. Sua aplicação vem sendo feita das mais diversas formas, mas principalmente para avaliar mudanças que ocorrem durante a operação da barragem, seja no corpo ou na fundação. Neste cenário, um melhor entendimento da conexão entre os resultados do monitoramento geofísico e a seu significado relacionado à segurança de barragens pode ajudar os engenheiros responsáveis por tais estruturas a adquirir informações importantes para tomadas de decisão (Adamo *et al.*, 2020).

Estes métodos levam em consideração que a maioria dos sólidos emitem um baixo nível de sinais sísmicos/acústicos quando submetidos a tensões ou quando sofrem deformações e uma variedade de termos é utilizada por várias disciplinas para descrever este fenômeno, como emissão acústica, atividade microssísmica, atividade sísmico-acústica, entre outros (Hardy Jr., 2003). A Figura 3 ilustra a forma como duas técnicas de monitoramento comumente utilizadas no meio geotécnico funcionam. Na primeira são utilizados dois transdutores: um transmissor que gera o sinal que será transmitido pelo material e; um receptor, que monitora as mudanças no sinal. Qualquer mudança nas características do sinal monitorado ocorre em função de alterações no meio monitorado. Na segunda, é utilizado somente um transdutor receptor, podendo ser um ou mais, que monitora sinais acústicos gerados no próprio material, denominado monitoramento passivo. Qualquer que seja a técnica de monitoramento utilizada, é importante destacar que se trata de um monitoramento indireto, que não permite determinar diretamente as propriedades do material analisado, somente monitorando alterações no sinal em função de mudanças no material. Essas mudanças são associadas às variações nas propriedades mecânicas.

Em relação às fontes que geram os sinais monitorados de forma passiva, elas estão relacionadas aos processos de deformação dos materiais. Esses processos ocorrem no nível macroscópico principalmente com a formação de fissuras, já no nível microscópico estão relacionadas a pequenos deslocamentos, microfissuras e também a alterações na distribuição granulométrica (Hardy Jr., 2003).

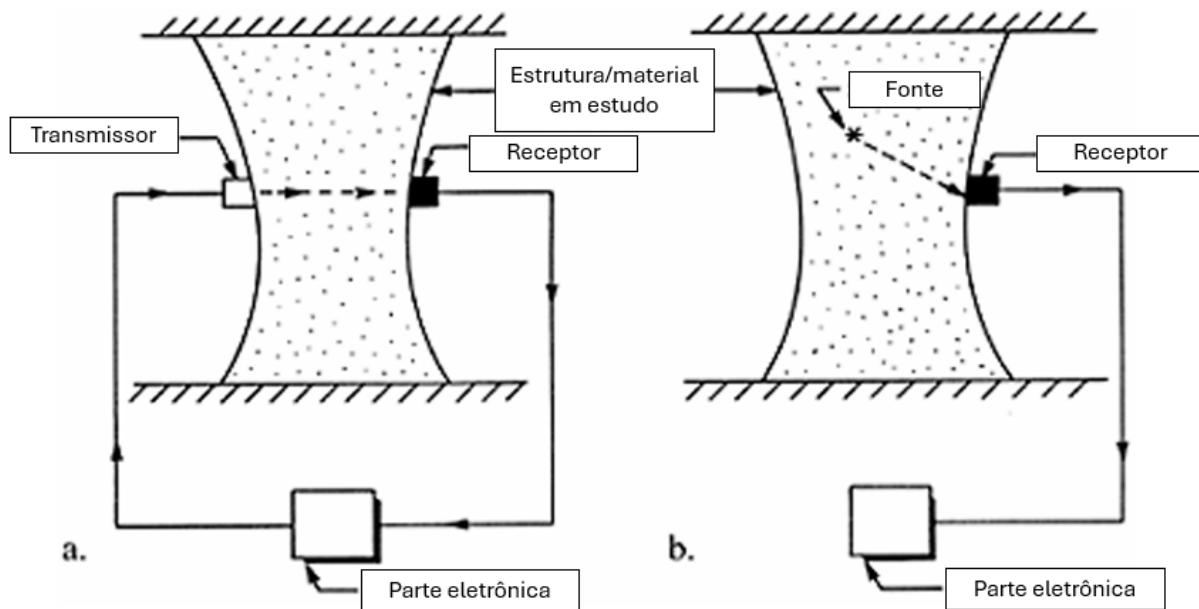


Figura 3 – Técnicas de monitoramento acústico utilizada para o monitoramento de materiais/estruturas geológicas: (a) Método sônico; (b) Métodos sísmicos/acústicos (Modificado de Hardy Jr., 2003).

Usualmente, nos trabalhos que constam na literatura, busca-se coletar dados que refletem, de maneira indireta e não destrutiva, os fenômenos de erosão interna em barragens. Nestes casos, a qualidade, quantidade e continuidade de dados são questões importantes. Os métodos não destrutivos inspecionam falhas que são invisíveis aos olhos devido ao seu tamanho ou localização. A aplicação destes métodos como ferramentas de diagnóstico é geralmente baseada na maximização da segurança e minimização dos custos associados aos esforços de implementação do monitoramento e mitigação dos possíveis danos ao barramento.

De maneira mais geral, os métodos não destrutivos para detecção precoce de *piping* buscam detectar os vazios no corpo da barragem, seja pela ausência de solo, seja pela presença de água nos caminhos em formação. Para o primeiro caso, métodos acústicos já tiveram uso reportado na literatura. Lu & Wilson (2012) utilizaram tanto técnicas ativas quanto passivas de monitoramento acústico para estudar a evolução da erosão interna em laboratório. Os resultados

obtidos pelos autores mostraram que, no monitoramento ativo, a variação da velocidade das ondas P monitoradas refletiu a evolução do processo de erosão interna, o aumento das poropressões positivas e a saturação do solo adjacente ao tubo. Já no monitoramento passivo, o desenvolvimento do piping pode ser identificado ao avaliar as alterações nos domínios do tempo e da frequência e nos contrastes dos espectrogramas.

Rittgers *et al.* (2015) propõem um novo método para combinar as informações de sinais elétricos e sísmicos passivos para detectar, localizar e monitorar alterações no comportamento hidráulico e mecânico de meios porosos por meio de um experimento em escala de campo. As alterações simuladas pelas alterações estão relacionadas ao desenvolvimento de um caminho de fluxo preferencial no corpo da barragem, associado ao desenvolvimento de *piping*. Os autores apresentaram um algoritmo de busca em malha 4D para a localização de emissões acústica no tempo e no espaço. Os resultados dessa localização foram utilizados para construir um conjunto de pesos para um modelo invariante do tempo, mas espacialmente variável. Os resultados obtidos pelos autores por meio da combinação das duas técnicas de monitoramento mostram-se consistentes em termos da observação do fluxo de água subterrâneo em barragens.

Planès *et al.* (2016) utilizaram interferometria sísmica passiva para monitorar as mudanças nos barramentos devido a erosões internas. Em resumo, os autores detectaram mudanças nas velocidades das ondas sonoras advindas do próprio ambiente quando passavam pelo barramento íntegro e comprometido. Os resultados mostraram reduções de até 20% na velocidade de onda de superfície à medida que a erosão interna progrediu. Os autores destacam ainda que algumas variações locais da velocidade mostraram boa correlação com variações na poropressão.

Fisher *et al.* (2016) investigaram técnicas para monitoramento de integridade de barragens de terra e detecção automática de eventos anômalos em dados sísmicos passivos detectados por meio de geofones. Desenvolveram um novo fluxo de trabalho orientado a dados que usa inteligência artificial (*Machine Learning*) e dados geofísicos coletados por sensores localizados na superfície do barramento para identificar eventos de erosão interna.

Parekh (2016) discute a aplicação de métodos geofísicos, por meio de uma combinação de métodos acústicos e elétricos para detecção e monitoramento contínuo da iniciação da erosão interna subsuperficial em seus estágios iniciais. O autor investiga a adequação da emissão acústica passiva, do auto potencial e da tomografia *cross-hole* para adequação como técnicas de monitoramento a longo prazo, remotas e contínuas para erosão interna e rachaduras de barragens de aterro.

Rahimi *et al.* (2019) utilizaram ondas sísmicas de superfície resultantes de ensaios realizados em uma barragem no Arkansas que historicamente apresentava problemas significativos de infiltração e erosão interna, para detectar locais de infiltração para fins de remediação e mapeamento. Os caminhos de infiltração na barragem foram detectados pela comparação das medidas de resistividade obtidas em dois períodos diferentes, mostrando-se um método útil para localizar potenciais zonas frágeis de maneira econômica e rápida.

Ozelim *et al.* (2022) utilizaram dados acústicos de um modelo reduzido em laboratório que simulava uma descontinuidade no corpo do barramento, para discutir as condições da estrutura e a detecção da presença da descontinuidade com o uso de algoritmos de inteligência artificial supervisionados. Os dados do monitoramento foram pré-processados para reduzir sua dimensionalidade utilizando os 3 parâmetros de Hjorth. Esses parâmetros são calculados a partir dos dados de monitoramento com o objetivo de diminuir a dimensionalidade e são eles: atividade, mobilidade e complexidade. A metodologia desenvolvida pelos autores permitiu observar que os parâmetros de mobilidade e complexidade estão relacionados com o nível de homogeneidade da barragem, enquanto o parâmetro de mobilidade estava relacionado com a presença de fluxo.

Os trabalhos apresentados até o momento utilizaram o monitoramento geofísico com o objetivo de observar que as alterações causadas pelo desenvolvimento de *piping* nas estruturas eram evidenciadas por alterações nos sinais sísmicos/acústicos monitorados. Este tipo de abordagem destaca a aplicabilidade do método. Na prática da engenharia de barragens, a obtenção de parâmetros que refletem de forma mais direta as alterações monitoradas torna-se interessante por permitir traduzir essas observações em medidas de engenharia. Outras aplicações para utilização de métodos geofísicos com estes objetivos podem ser encontradas na literatura. Strahser *et al.* (2011) discutem a utilização de sinais sismoelétricos induzidos pela propagação de ondas sísmicas para analisar variações no teor de umidade do solo. Neste caso, os autores utilizaram um intervalo relativamente baixo de resistência, correspondendo a altos valores de grau de saturação.

Pirogova *et al.* (2019) discutem a utilização de métodos sísmicos de alta resolução para estimar propriedades elásticas de sedimentos depositados nos mares. Para isso, foi utilizado um método de inversão acústica denominado AVA, baseado nas equações não-lineares de Zoeppritz, que relacionam os coeficientes de refração e reflexão de ondas para diferentes ângulos de incidência. Os resultados mostram que é possível analisar não somente as propriedades acústicas como também as propriedades elásticas dos solos analisados.

Uyanık (2019) desenvolveu um estudo em um depósito de solo predominantemente argiloso em que foi feita a estimativa da porosidade dos solos utilizando as velocidades das ondas P e S monitoradas. No estudo vários parâmetros elásticos foram calculados, como o módulo de compressibilidade, o módulo de cisalhamento e o coeficiente de Poisson, por meio do método de refração sísmica. Foram realizados ensaios de laboratório nas amostras retiradas e alguns dos parâmetros obtidos foram utilizados para determinar relações empíricas com os parâmetros monitorados. Os resultados mostraram que, além de ser possível relacionar o monitoramento à variação da porosidade, a mudança na velocidade de onda S está diretamente relacionada ao grau de rigidez do solo.

Minakov & Yarushina (2021) propõem um modelo elastoplástico com base em resultados de monitoramento sísmico e acústico. Os autores indicam que estudos laboratoriais recentes em emissões acústicas em rochas ajudam a conectar os componentes do tensor do momento sísmico com processos de falha. Os autores propõem uma nova representação de fontes sísmicas derivadas da lei de fluxo plástico não associativa, que ajuda a prever o padrão de fratura localizada e resposta sísmica correspondente. Para isso, foi utilizada uma formulação incremental quase-estática, onde as deformações plásticas foram incorporadas com uma parte da força de corpo efetiva na equação de propagação de onda.

Conforme indicado por Yousefpour & Mojtabahedi (2023), a relação entre erosão interna e os sinais sísmicos é influenciada por diversos fatores como o tipo de solo, as condições de tensão e saturação. Os autores indicam que outros fatores como, microfissuras, o movimento de partículas do solo e alterações na poropressão podem alterar as características do sinal sísmico. A hipótese levantada no trabalho é de que mudanças nos padrões dentro dos sinais sísmicos podem fornecer conhecimento sobre os processos que causam o início da erosão interna em barragens de terra, destacando a possibilidade de relacionar diretamente os resultados do monitoramento com as alterações ocorridas.

### **2.3. MODELOS REDUZIDOS DE BARRAGEM PARA MONITORAMENTO DE PIPING EM LABORATÓRIO**

Diversos trabalhos na literatura fizeram o uso de modelos reduzidos para simular *piping* em laboratório ou em campo. Nesta seção serão exploradas as dimensões dos modelos construídos, os materiais utilizados na construção, a forma como foi induzido o *piping*, o tipo de sensor utilizado e o estado do modelo após o ensaio.

No experimento conduzido por Fisher *et al.* (2017a) foi construída uma estrutura com 4,27m de comprimento e 0,91m de altura. Para induzir o *piping*, uma barra com 48,26 centímetros foi inserida abaixo da crista. Após o enchimento e estabilização do fluxo, a barra foi retirada do modelo para simular o fenômeno. Para o monitoramento do modelo foram utilizados geofones de 500 Hz. O resultado da erosão do modelo mostra uma quantidade significativa de material carreado, conforme demonstrado na Figura 4.

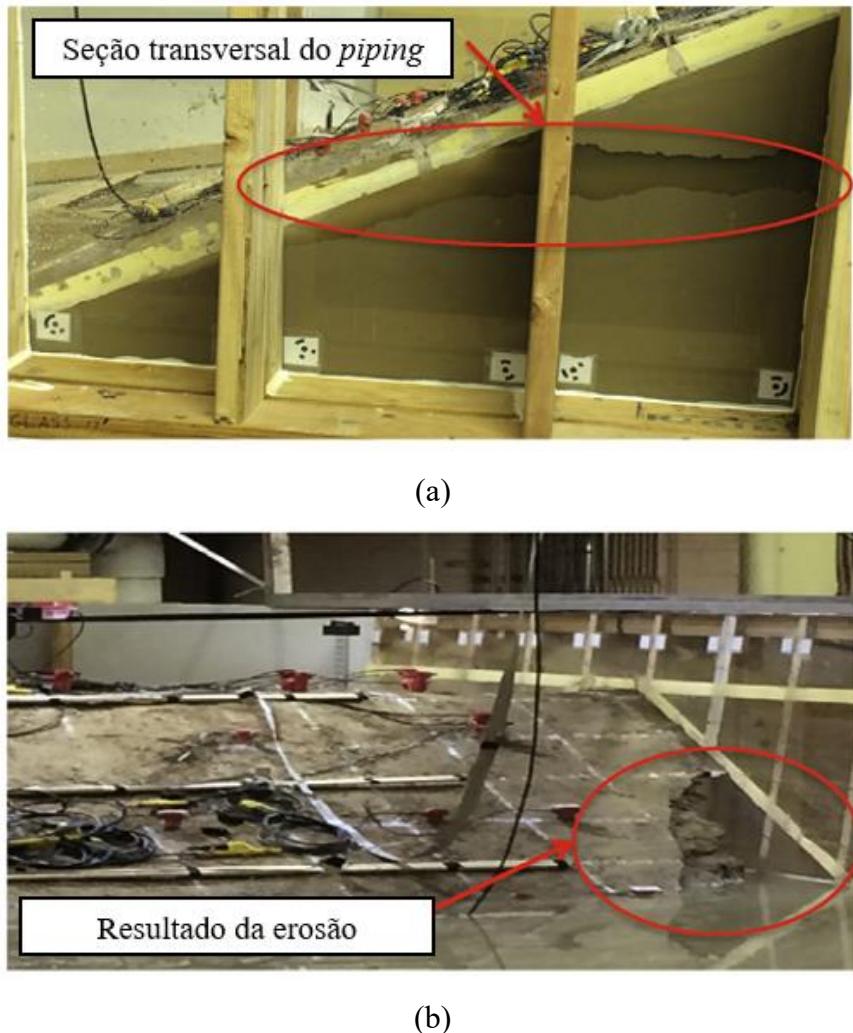


Figura 4 – Estrutura construída para simular o *piping* em laboratório: (a) seção transversal após a remoção da barra; (b) resultado da simulação (Modificado de Fisher *et al.*, 2017a).

O modelo em escala de laboratório de Planès *et al.* (2016) foi construído em um canal trapezoidal com 21,3m de comprimento e 6,10m de largura (Figura 5a). O material utilizado na construção do aterro foi uma areia siltosa de baixa plasticidade. O solo foi compactado a uma densidade de 0,5% da densidade máxima utilizando o Proctor Normal na umidade ótima. Os primeiros 30cm do aterro foram compactados a 98% da densidade máxima, enquanto os últimos

36cm foram compactados a 87% da densidade máxima. Durante a construção, uma barra com 1,3cm de diâmetro foi inserida no corpo do barramento 25cm abaixo da crista e se estendendo do reservatório à face de jusante (Figura 5b). Para monitorar a estrutura, dez geofones de componente vertical foram posicionados na crista do aterro com 61cm de espaçamento. Os geofones utilizados possuíam uma largura de banda de 20 a 400 Hz. A evolução do piping induzido pelos autores pode ser observado na Figura 5c, onde é possível notar que há uma quantidade considerável de material carreado durante o ensaio.

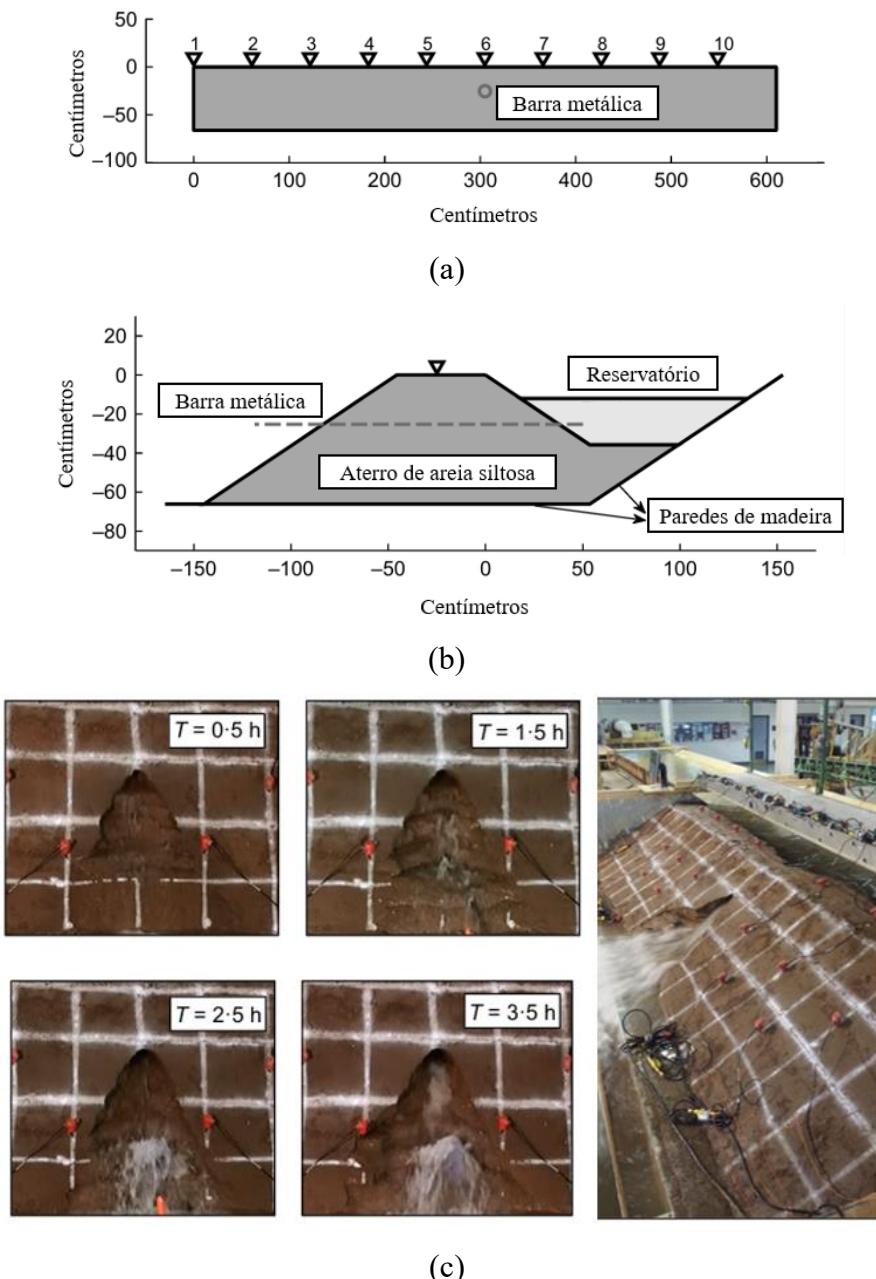


Figura 5 – Modelo em escala de laboratório para simulação de *piping*: (a) vista frontal e; (b) seção transversal; (c) resultado da erosão após 0,5h, 1,5h, 2,5h, 3,5h e 5h após iniciação do *piping* (Modificado de Planès *et al.*, 2016).

No ensaio em larga escala conduzido por Hanson *et al.* (2010) foi montada uma barragem com 1,3m de altura, 1,8m de largura da crista e 9,6m de largura da base. Para induzir o *piping* foi utilizada uma barra metálica de 40mm de diâmetro. Assim que o nível d'água se manteve constante no reservatório, a barra metálica foi removida e iniciou-se o processo de carreamento do material. A evolução da descontinuidade induzida na barragem está apresentada na Figura 6.



Figura 6 – Evolução da ruptura do modelo de barragem em larga escala (Hanson *et al.*, 2010).

Hickey *et al.* (2009) montaram um ensaio em larga escala para monitoramento de erosão interna utilizando sísmica passiva. O aterro montado pelos autores possuia 12m de comprimento e 1,25m de altura, construído ao longo de um canal controlado. A compactação do material foi feita em uma série de 11 camadas de aproximadamente 11cm de espessura. Durante o processo de compactação um tubo metálico foi introduzido no corpo do barramento, sendo removido posteriormente para criar um canal inicial e iniciar o processo de erosão. As características do material utilizado na construção estão apresentadas na Figura 7a. Após a remoção do tubo, a evolução da erosão induzida no barramento foi considerável, conforme pode ser observado na Figura 7b. O monitoramento do processo de erosão foi feito com o uso de acelerômetros.

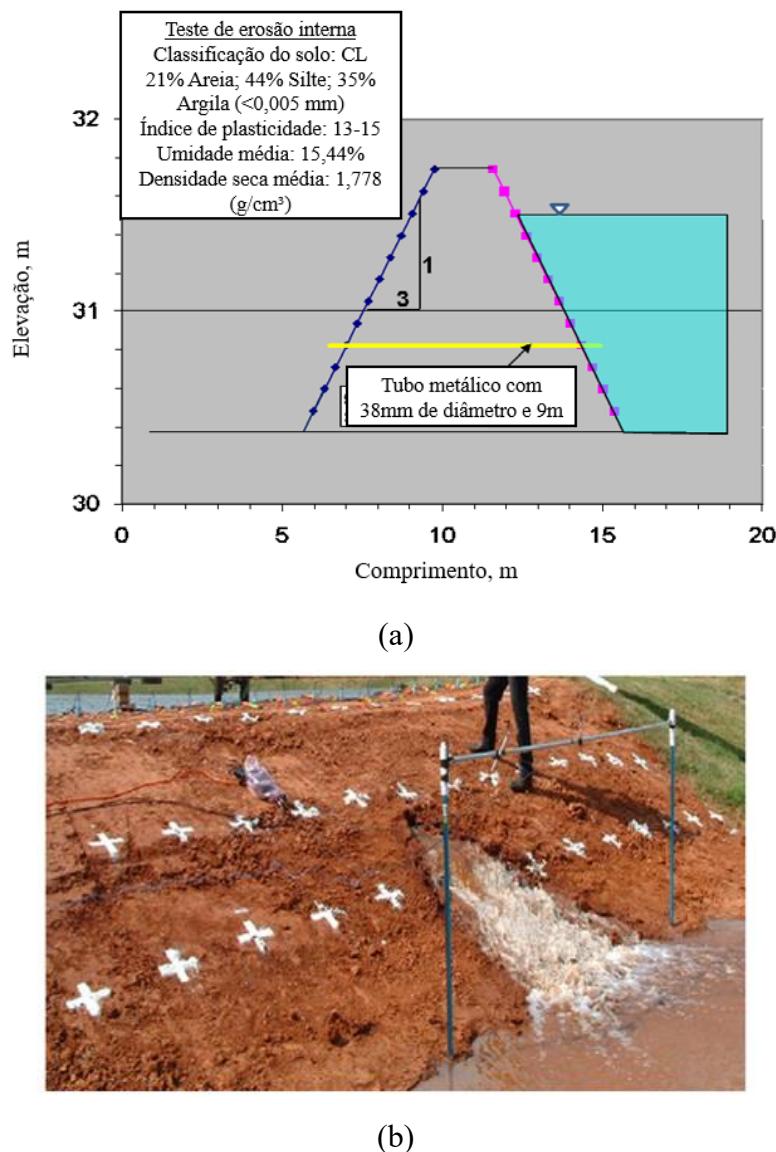


Figura 7 – Modelo de barragem para simulação de piping: (a) seção transversal; (b) resultado da erosão (Modificado de Hickey *et al.*, 2009).

Os resultados dos estudos que constam na literatura mostram a versatilidade dos métodos geofísicos para monitoramento de alterações em estruturas geotécnicas. Na maioria dos casos, em função do volume de dados, o uso da inteligência artificial para análise dos resultados do monitoramento se mostra como a alternativa mais explorada, principalmente nos casos em que se procura encontrar padrões de comportamento para um certo conjunto de dados. Esse uso deve ser precedido pela preparação dos dados. No caso de dados proveniente de monitoramento sísmico/acústico essa preparação é feita por meio da extração dos atributos que representam a configuração do sinal monitorado em cada instante de tempo.

## 2.4. PREPARAÇÃO DE DADOS SÍSMICOS PARA DETECÇÃO DE ANOMALIAS

A escolha do modelo de *Machine Learning* mais eficiente para a previsão de anomalias no meio poroso está condicionada ao tratamento prévio dos sinais acústicos pautado, portanto, no processamento dos dados de entrada e na extração dos seus principais atributos, incluindo, sua organização na forma vetorial. A extração dos atributos é uma etapa de processamento essencial tanto para reconhecimento de padrões quanto para as tarefas de aprendizado de máquina. Os dados de áudio são intrinsecamente volumosos, portanto, a redução da taxa de dados se faz necessária. Assim, com essa etapa, os algoritmos de análise ficam condicionados a uma quantidade pequena de recursos que representam as propriedades dos sinais acústicos captados originalmente (Giannopoulos & Pikrakis, 2014). Caso os atributos não sejam adequadamente selecionados nessa fase, há comprometimento de todas as etapas subsequentes. Os principais atributos das ondas acústicas podem ser categorizados em relação ao seu domínio, isto é, em função do tempo e da frequência.

De modo geral, essas propriedades de domínio do tempo são extraídas diretamente dos sinais acústicos, sendo elas:

- Envelope de Amplitude (*Amplitude Envelope* - AE): representa o volume do sinal, por meio da extração do valor máximo de amplitude de cada amostra contida em uma janela de análise (Albuquerque *et al.*, 2022). Os autores indicam que amplitudes elevadas são indicativas de eventos barulhentos, como rachaduras ou *piping*. Tal atributo é calculado por meio da equação (1).

$$AE_t = \max_{k=t..K}^{(t+1)(K-1)} s(k) \quad (1)$$

Onde, K é o tamanho da janela de análise e s(k) simboliza a amplitude da amostra k.

- Energia Quadrada Média (*Root-Mean Square Energy* - RMS): pode ser obtida por meio da equação (2) e é similar ao envelope de amplitude, porém é menos sensível aos valores destoantes de cada amostra no sinal acústico. Representa, portanto, uma “altura” e detecta diferentes tipos de ruído em cada parte do sinal (Albuquerque *et al.*, 2022). Os autores indicam que o RMS, assim como a AE, é uma propriedade de sinais acústicos importante para os eventos de erosão e fissuração, por ser um indicativo dos barulhos, como do fluxo de água ou no desenvolvimento de rachaduras ou *piping*.

$$RMS_t = \sqrt{\frac{1}{K} \sum_{k=t,K}^{(t+1)(K-1)} s(k)^2} \quad (2)$$

- Taxa de cruzamento com o zero (*Zero-Crossing Rate* - ZCR): diz respeito ao número de vezes que o sinal muda de valor, de positivo para negativo, indicando a quantidade de vezes que este cruza o eixo x. É calculado por meio da equação (3) e pode ser interpretado como uma medida de quão ruidoso é o sinal (Giannopoulos & Pikrakis, 2014). Os autores indicam que esse parâmetro reflete de certa forma, as características espectrais do sinal.

$$ZCR_t = \frac{1}{2} \sum_{k=t,K}^{(t+1)(K-1)} |sinal(s(k)) - sinal(s(k+1))| \quad (3)$$

Onde,  $sinal(s(k))$  refere-se ao sinal da função  $s(k)$  atribuído de acordo com os valores de amplitude, isto é,

$$sinal(s(k)) = \begin{cases} 1, & s(k) > 0 \\ -1, & s(k) < 0 \\ 0, & s(k) = 0 \end{cases}$$

Os atributos do domínio da frequência revelam importantes características do sinal acústico, a maioria dos atributos mais importantes para análise destes sinais estão neste domínio. Estes são obtidos por meio da transformação do dado (originalmente representado no domínio do tempo) para o domínio da frequência (espectral) mediante transformações ou autocorrelações, sendo que as ferramentas de transformação mais usuais são: a Transformada Discreta de Fourier (TDF) e a Transformada Discreta de Cosseno (TDC) (Mitrovic *et al.*, 2010). Dentre as propriedades do domínio da frequência, destaca-se:

- Centroide espectral: representa uma medida da posição e da forma do espectro. O centroide espectral é o centro de “gravidade” do espectro (Giannopoulos &

Pikrakis, 2014). O valor do centroide  $C_i$  no  $i$ -ésimo *frame* de áudio é definida conforme apresentado na equação (4):

$$C_i = \frac{\sum_{k=1}^{W_{FL}} k X_i(k)}{\sum_{k=1}^{W_{FL}} X_i(k)} \quad (4)$$

Onde,  $X_i(k)$ ,  $k = 1, \dots, W_{FL}$  é a magnitude dos coeficientes da TDF no  $i$ -ésimo *frame* de áudio. E  $W_{FL}$  é o número de coeficientes utilizados.

- *Rolloff* espectral: é definido como a frequência abaixo da qual uma certa porcentagem da distribuição de magnitude do espectro está concentrada, normalmente refere-se a porcentagens por volta de 90% (Giannopoulos & Pikrakis, 2014). Se o  $m$ -ésimo coeficiente da TDF corresponde ao *rolloff* espectral do  $i$ -ésimo *frame*, então a equação (5) é satisfeita.

$$\sum_{k=1}^m X_i(k) = C \sum_{k=1}^{W_{FL}} X_i(k) \quad (5)$$

Outros atributos que podem ser extraídos do domínio da frequência são a Razão de Energia de Banda, a Largura de Banda Espectral, a Planicidade espectral, que se refere à quantificação do quanto o sinal é parecido com um ruído ou se possui uma tonicidade associada, e os coeficientes do Cepstrum de Frequência Mel (*Mel-Frequency Cepstrum Coefficients* - MFCCs), muito populares para o reconhecimento da voz. Os MFCCs são um tipo cepstral de representação do sinal acústico, no qual as bandas de frequência são distribuídas de acordo com a escala Mel (Giannopoulos & Pikrakis, 2014). Os MFCCs são obtidos por meio da aplicação da Transformada Discreta de Cosseno (TDC) que resultam em coeficientes relacionados à parte real da Transformada de Fourier.

## 2.5. INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO DE ANOMALIAS

Após a preparação dos dados, um caminho comumente adota na literatura é a inserção destes em um modelo de IA para detecção de anomalias que possam ser indicativas da ocorrência de *piping*. Entende-se como detecção de anomalias a procura por instâncias ou padrões nos dados que apresentam um desvio em relação ao comportamento normal esperado. Ferramentas para detecção de anomalias são interessantes pois elas normalmente indicam informações úteis para tomadas de decisão (Singh, 2017). A detecção de fraude em sistemas

financeiros e falhas em sistemas industriais são algumas das aplicações de algoritmos de detecção de anomalias encontradas na literatura.

Um aspecto importante da detecção de anomalias refere-se à natureza da anomalia que se deseja detectar. Chandola *et al.* (2009) classificam as anomalias em três tipos:

- Anomalias pontuais: caso uma única instância do dado possa ser considerada anômala quando comparada com os outros. É o tipo mais simples de anomalia, sendo o foco na maioria das pesquisas;
- Anomalias contextuais (ou anomalias condicionais): caso uma instância de dado possa ser considerada anômala em um contexto específico, mas não fora dele;
- Anomalias coletivas: caso uma coleção de dados relacionados possa ser considerada anômala em relação ao banco de dados total. Dados individuais dentro de uma anomalia coletiva podem não ser uma anomalia quando analisados sozinhos, mas a sua ocorrência em grupo é considerada anômala.

Uma forma comum de lidar com um problema de detecção de anomalia é definir uma região que representa o comportamento normal e classificar que os dados que não se encaixam nesse comportamento como anormais. O grande problema dessa abordagem é definir o que é o comportamento normal, determinar um limite que comporte todas as regiões do que pode ser considerado normal é extremamente difícil, adicionalmente os limites que definem o comportamento como anômalo muitas vezes não é preciso, podendo um dado normal ser classificado como anômalo ou vice-versa (Chandola *et al.*, 2009).

A aplicação dessas abordagens no contexto da detecção de *piping* traz uma discussão interessante, uma vez que determinar a ocorrência do fenômeno utilizando algoritmos não supervisionados é uma tarefa complicada, pois deve-se conhecer o que significa o comportamento normal do sensor para estabelecer os cenários com anomalia. No cenário atual, tanto no Brasil como no mundo, onde existem muitas barragens em operação, o conhecimento do comportamento sem anomalia pode ser difícil de determinar. Desta forma, uma maneira de abordar o problema seria caracterizar o comportamento sísmico/acústico esperado da barragem. Nos casos em que é possível conhecer o comportamento esperado para cada situação, seja com ou sem anomalia, podem ser utilizados algoritmos de classificação ou regressão para avaliação de novos dados.

A classificação e a regressão são as duas principais categorias de tarefas no aprendizado supervisionado (Lee, 2025a). Embora ambas utilizem dados rotulados para treinar modelos, seus objetivos e os tipos de problemas que resolvem são fundamentalmente diferentes. A classificação se ocupa de prever resultados discretos ou categóricos. Exemplos clássicos

incluem a identificação de e-mails como "spam" ou "não spam", o diagnóstico de uma condição médica como "maligna" ou "benigna", ou a categorização de imagens em classes como "cão", "gato" ou "carro". As tarefas de classificação podem ser subdivididas em:

- Classificação Binária: Onde existem apenas duas categorias de saída possíveis (fraude/não fraude).
- Classificação Multiclasse: Onde existem mais de duas categorias mutuamente exclusivas (classificar a raça de um cão).
- Classificação Multirrotulo: Onde uma única instância pode ser associada a múltiplas categorias simultaneamente (rotular um filme como "ação" e "comédia").

Por outro lado, a regressão visa prever resultados contínuos ou valores numéricos. Exemplos incluem a estimativa do preço de uma casa com base em suas características, a previsão da pressão arterial de um paciente ou a projeção do valor de uma ação.

Se tratando de uma série de diferentes modelos de classificação, a avaliação do desempenho de cada um é tão crucial quanto seu treinamento, e as métricas utilizadas diferem significativamente entre classificação e regressão, refletindo seus objetivos distintos. Para a classificação, as métricas avaliam quão bem o modelo consegue separar as classes. Géron (2019) descreve as principais métricas, que incluem:

- Acurácia: representa a proporção de previsões corretas sobre o total. Embora intuitiva, pode ser enganosa em conjuntos de dados desbalanceados.
- Precisão: representa de todas as previsões positivas, quantas estavam corretas, sendo calculada conforme indicado na equação 6. Onde, TP refere-se aos verdadeiros positivos e FP aos falsos positivos.

$$Precisão = \frac{TP}{TP + FP} \quad (6)$$

- *Recall* ou sensibilidade: representa de todos os positivos reais, quantos foram corretamente identificados, sendo calculado conforme apresentado na equação 7, onde FN refere-se aos falsos negativos.

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

- F1-Score: representa a média harmônica da precisão e do recall, fornecendo um equilíbrio entre os dois e sendo calculado conforme apresentado na equação 8.

$$F1 = 2 \cdot \frac{precisão \cdot recall}{precisão + recall} \quad (8)$$

Outra forma de representar os resultados de um algoritmo de classificação é por meio da matriz de confusão, uma tabela que detalha os verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos, fornecendo uma visão geral dos erros do modelo.

Para a regressão, as métricas medem a proximidade entre os valores previstos e os valores reais, conforme descrito por (Lee, 2025a):

- Erro Quadrático Médio (MSE): representa a média dos quadrados das diferenças entre os valores previstos e reais, penalizando erros maiores de forma mais significativa. O MSE é calculado por meio da equação 9.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

- Raiz do Erro Quadrático Médio (RMSE): representa a raiz quadrada do MSE, retornando a métrica de erro para a mesma escala dos dados originais.
- Erro Absoluto Médio (MAE): representa a média das diferenças absolutas, sendo menos sensível a *outliers* do que o MSE. O MAE é calculado por meio da equação 10.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

- Coeficiente de Determinação ( $R^2$ ): Indica a proporção da variância na variável dependente que é previsível a partir das variáveis independentes. Varia de 0 a 1, com valores mais altos indicando um melhor ajuste. O  $R^2$  é calculado por meio da equação 11.

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (11)$$

A escolha da métrica de avaliação apropriada não é apenas uma decisão técnica, mas um reflexo direto dos objetivos ou do contexto da aplicação. As fórmulas matemáticas para precisão e *recall*, por exemplo, não capturam o custo assimétrico dos diferentes tipos de erro no mundo real. Em um cenário de diagnóstico médico, como a detecção de câncer, um falso negativo (não detectar uma doença existente) tem consequências muito mais graves do que um falso positivo (sugerir uma doença que não existe, levando a mais exames). Nesse contexto, o *recall* (a capacidade de identificar todos os casos positivos reais) é priorizado, mesmo que isso signifique uma precisão menor. Em contraste, em um sistema de filtragem de spam, um falso positivo (um e-mail importante ser classificado como spam) é frequentemente considerado mais problemático do que um falso negativo (um e-mail de spam chegar à caixa de entrada). Aqui, a precisão é a métrica mais crítica. Portanto, a avaliação de um modelo é indissociável da análise

do custo do erro em seu domínio de aplicação, transformando a seleção de métricas em uma tradução de prioridades estratégicas para um critério quantificável.

Dentre os algoritmos de classificação comumente utilizados, cita-se:

- Regressão Logística (*Logistic Regression*): tem como função modelar a probabilidade de um resultado categórico, tipicamente binário. O desafio central que esse tipo de algoritmo resolve é como usar uma função linear para prever uma probabilidade. A solução não é modelar a probabilidade diretamente, mas sim uma transformação dela por meio do logaritmo da razão de chances. A principal vantagem desse tipo de algoritmo está relacionada à sua simplicidade, enquanto a sua principal limitação está relacionada à hipótese de que há uma relação linear entre as entradas no logaritmo da razão de chances, o que nem sempre é verdade. Além disso, o modelo é sensível a *outliers* e a alta correlação entre as variáveis de entrada (Lee, 2025b).
- Máquinas de Vetores de Suporte (*Support Vector Machines* - SVM): são algoritmos baseados na teoria de aprendizagem estatística de Vapnik-Chervonenkis e no princípio de minimização do risco estrutural (Bhavsar & Panchal, 2012). Conforme descrito pelos autores, o objetivo central do SVM é identificar um hiperplano no espaço de dados de entrada que separe os dados de diferentes classes da melhor forma possível. A maior força do SVM reside em sua capacidade de lidar com dados não linearmente separáveis por meio do *kernel trick*. Em vez de tentar ajustar uma fronteira não linear no espaço original, a SVM utiliza uma função de kernel (polinomial, Função de Base Radial ou Sigmoide) para mapear os dados para um espaço de dimensão muito maior. A ideia é que, nesse espaço de dimensão superior, os dados se tornem linearmente separáveis. A principal desvantagem deste método está relacionada ao custo computacional associado.
- Gradiente Descendente Estocástico (*Stochastic Gradient Descent* - SGD): representa uma abordagem simples e eficaz para o treinamento de modelos lineares. Sua aplicação é ideal em cenários que utilizam funções de perda convexas, como a Regressão Logística e as Máquinas de Vetores de Suporte lineares. Em sua essência, o SGD é estritamente uma técnica de otimização, e não uma família específica de modelos de aprendizado de máquina. Trata-se apenas do método utilizado para treinar um modelo (Scikit-learn, 2025).
- Naive-Bayes: algoritmo fundamentado no Teorema de Bayes, que retorna a probabilidade de um evento com base no conhecimento prévio de condições que podem estar relacionadas a este evento. As vantagens desse algoritmo estão associadas à sua

simplicidade e de que ele não requer uma grande quantidade de dados para estimar as probabilidades. A maior desvantagem deste tipo de algoritmo está associada à suposição de independência entre as variáveis (IBM, 2025a).

- *K-Nearest Neighbors* (kNN): é algoritmo simples que opera sob a suposição de que pontos de dados semelhantes existem em proximidade uns dos outros. Ao contrário da maioria dos outros algoritmos, o kNN não passa por uma fase de treinamento explícita para aprender um modelo, em vez disso o algoritmo memoriza todo o conjunto de dados de treinamento e calcula a distância entre o ponto de consulta e todos os outros pontos nesse conjunto de dados. Em seguida o algoritmo identifica o ‘k’ pontos mais próximos e a nova amostra é atribuída à classe que é mais frequente entre esses ‘k’ vizinhos. A principal vantagem deste tipo de algoritmo está relacionada à sua simplicidade, porém em espaços de alta dimensão o conceito de proximidade se torna menos significativo, pois todos os pontos tendem a estar distantes um dos outros, degradando consideravelmente o desempenho do algoritmo, sendo sua principal desvantagem (IBM, 2025d).
- Árvores de decisão (*Decision Trees*): é um algoritmo não paramétrico que se destaca por sua estrutura intuitiva e sua capacidade de gerar regras de decisão simples. O algoritmo funciona como uma série de regras “se-então” a partir das *features* dos dados, que são organizadas em uma estrutura hierárquica semelhante a uma árvore. As raízes da árvore atuam como a entrada de dados e a cada nó de decisão a partir da raiz o algoritmo procura a melhor *feature* e o melhor ponto de corte para dividir os dados em dois ou mais subconjuntos. A principal desvantagem deste tipo de algoritmo é a sua tendência a *overfitting*, podendo criar árvores excessivamente complexas que se ajustam bem às variações dos dados de treinamento, mas que não funcionam bem em novos dados (IBM, 2025b).
- Florestas aleatórias (*Random Forests*): algoritmo que opera construindo uma grande coleção de árvores de decisão descorrelacionadas durante o treinamento. Neste tipo de algoritmo a previsão final é determinada por uma espécie de “voto de maioria” entre todas as árvores da floresta. A chave para o desempenho das florestas aleatórias é a garantia de que as árvores individuais sejam diversas, por meio da separação do conjunto de dados para cada árvore. Trata-se de um dos algoritmos mais robustos disponíveis, que combate eficazmente o *overfitting* e permite obter a importância das variáveis (IBM, 2025c).

- *Multilayer Perceptron* (MLP): conforme descrito por Baladram (2024), é um tipo de algoritmo de *deep learning* na forma de uma rede neural *feedforward*, o que significa que os dados fluem em uma única direção. A estrutura de um MLP simula o funcionamento de um neurônio, sendo formado por uma camada de entrada, que recebe os dados brutos, um número arbitrário de camadas ocultas e uma camada de saída, que produz a predição. O treinamento de um MLP é realizado através do algoritmo de retropropagação (*backpropagation*). O processo começa com uma passagem para a frente (*forward pass*), onde os dados de entrada são propagados através da rede neural para gerar uma predição. Em seguida, uma função de perda é calculada para medir o erro entre a predição e o rótulo verdadeiro. A retropropagação então calcula o gradiente da função de perda em relação a cada peso e viés na rede, começando pela camada de saída e movendo-se para trás. Finalmente, um algoritmo de otimização usa esses gradientes para atualizar os pesos e vieses, movendo-os ligeiramente na direção que minimiza o erro. Este ciclo de *forward pass*, cálculo de perda, *backpropagation* e atualização de pesos é repetido diversas vezes até que o modelo convirja. A principal vantagem do MLP é sua capacidade de aprender padrões e relações não lineares extremamente complexas, tornando-o adequado para uma vasta gama de problemas de classificação que os modelos lineares não conseguem resolver.

Dentre os algoritmos de regressão comumente utilizados, cita-se:

- *Random Forest Regressor*: conforme descrito por Biau & Scornet (2016), trata-se de um algoritmo que mantém a arquitetura do seu análogo de classificação, mas com modificações em como as árvores são construídas e como suas predições são agregadas. No que diz respeito ao processo de construção, em árvores de regressão o objetivo não é criar nós puros em termos de classe, mas sim criar nós onde os valores da variável de destino sejam o mais semelhante possível. Na predição final, em vez de ser um voto de maioria, esta é computada como a média das predições de todas as árvores de decisão individual. As vantagens e desvantagens desse tipo de modelo são as mesmas do algoritmo de classificação análogo.
- *Support Vector Regressor* (SVR): conforme descrito por Sidharth (2025), trata-se de uma adaptação do SVM para tarefas de regressão. Ele transpõe a ideia de maximizar a margem de separação para o problema de ajustar uma função a dados contínuos, introduzindo o conceito de uma margem de tolerância ao erro. Portanto, enquanto o SVM busca um hiperplano que maximize a distância entre as classes, o objetivo do SVR é encontrar um hiperplano que se ajuste ao maior número possível de pontos de dados

dentro de uma margem de erro predefinida. Esta margem é definida por um hiperparâmetro chave chamado  $\epsilon$  (épsilon). As vantagens do SVR derivam diretamente de seus princípios de funcionamento. A perda insensível a  $\epsilon$  o torna muito robusto a *outliers*, pois pontos ruidosos que ainda caem dentro do tubo de  $\epsilon$  não afetam o modelo final. Assim como a SVM, ele tem um bom desempenho em espaços de alta dimensão e é eficiente em termos de memória, pois sua solução depende apenas de um subconjunto dos dados de treinamento (os vetores de suporte). As desvantagens são também significativas. O SVR pode ser computacionalmente intensivo e lento para treinar em conjuntos de dados muito grandes, devido à sua complexidade de otimização.

### 3. MATERIAIS E METODOLOGIA

Para obter a medida transiente do parâmetro intermediário durante uma simulação do processo de desenvolvimento de *piping* em um modelo em escala de laboratório, foi estabelecido o comportamento esperado para este parâmetro por meio do monitoramento de cenários estáticos, como uma forma de caracterizar a resposta sísmica do sensor para o material sob diferentes condições. A associação da resposta sísmica do sensor com a quantificação do parâmetro intermediário em cada cenário estático foi feita por modelos de *Machine Learning* supervisionando para classificação e regressão. A escolha das condições iniciais do material de cada cenário estático foi pautada em estudos que fizeram a caracterização do material utilizado na construção do modelo de barragem. Os cenários foram montados e monitorados utilizando equipamentos adquiridos durante o projeto AINOA (Sistema de Monitoramento de Patologias Internas em Barragens de Terra e Enrocamento Fundamentado em Inteligência Artificial e Internet das Coisas: Caso de Estudo da Barragem do Paranoá-DF), em que o presente autor participou, atuando na equipe de desenvolvimento e monitoramento do modelo reduzido em laboratório. O algoritmo de IA adaptado também foi elaborado para o projeto, o presente trabalho utilizou o conhecimento construído na ocasião para o cálculo e seleção dos atributos de onda mais adequados. Para o desenvolvimento do algoritmo utilizado na presente pesquisa foi utilizada a linguagem de programação Python.

Neste capítulo estão descritos de forma detalhada os materiais utilizados na pesquisa, iniciando com a caracterização dos materiais geotécnicos utilizados, seguindo pela configuração do equipamento e do modelo de barragem construído em laboratório, descrição das características do equipamento utilizado no monitoramento sísmico e dos atributos extraídos dos dados. Em seguida, é detalhada a metodologia desenvolvida para o trabalho.

#### 3.1. MATERIAIS

##### 3.1.1. CARACTERIZAÇÃO DOS MATERIAIS GEOTÉCNICOS

O material utilizado na montagem dos cenários foi coletado no Campo Experimental do Programa de Pós-Graduação em Geotecnia da Universidade de Brasília (PPGG/UnB) (Figura 8). Optou-se pela utilização de um material argiloso, pois não é possível induzir uma ruptura por *piping* em uma areia, já que esta tende a apresentar um efeito cicatrizante, colapsando ao ser saturada e, portanto, um modelo de barragem com este material não consegue manter uma fissura aberta por tempo suficiente para permitir a simulação de *piping* (Fell & Fry, 2007).



Figura 8 – Localização do Campo Experimental do Programa de Pós-Graduação em Geotecnia (modificado de Google Earth, 2025).

O perfil estratigráfico do solo no campo experimental (Figura 9) mostra que, nas camadas mais superficiais, abaixo da camada de vegetação, tem-se uma camada de argila arenosa muito mole, que será o material utilizado na presente pesquisa. Este foi retirado à uma profundidade de aproximadamente 2 metros.

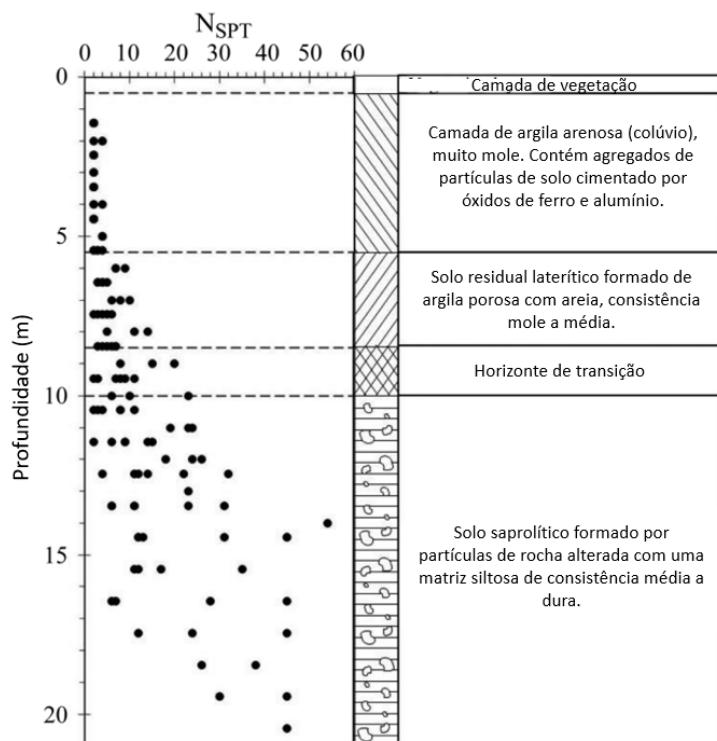


Figura 9 – Perfil estratigráfico do solo no Campo Experimental do PPGG/UnB (Modificado de Rebolledo *et al.*, 2019).

A curva granulométrica sem defloculante e com defloculante da argila arenosa utilizada, obtida por Lopes (2019), apresentada na Figura 10, reflete o comportamento característico do solo da região, em que há a formação de agregados de partículas de solo cimentado, por isso a diferença entre os resultados do ensaio feito com e sem defloculante.

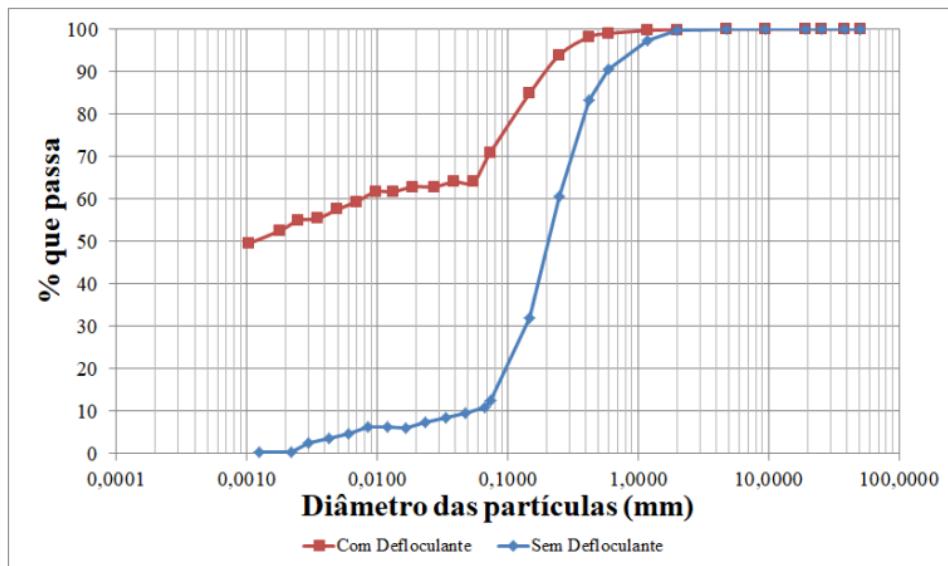


Figura 10 – Curva granulométrica da argila do Campo Experimental do PPGG/UnB (Lopes, 2019).

Para definição dos cenários foram utilizados resultados de ensaios de compactação em trabalhos na literatura que utilizaram o material do Campo Experimental. Foram comparados os pesos específicos mínimos e máximos atingidos nos ensaios para definir o maior intervalo de índice de vazios possível. No trabalho de Lopes (2019) foi utilizada a energia intermediária e foi atingido um peso específico seco máximo ( $\gamma_{d,\text{máx}}$ ) de 16,78 kN/m<sup>3</sup> com umidade ótima de 20,18%, enquanto que o peso específico seco mínimo ( $\gamma_{d,\text{mín}}$ ) do ensaio foi de 14,84 kN/m<sup>3</sup> com umidade de 16,74%. Collantes (2022) coletou amostras de material nas profundidades de 1, 3, 5 e 7 metros, e utilizando a energia intermediária e obteve um  $\gamma_{d,\text{máx}}$  de 16,61 kN/m<sup>3</sup>, com umidade ótima de 20,52%, e um  $\gamma_{d,\text{mín}}$  de 14,83 kN/m<sup>3</sup> com umidade de 16,96% para as amostras coletadas aos 3 metros de profundidade. Silva *et al.* (2024) coletaram amostras na profundidade de 2 metros e utilizou a energia normal na compactação, atingindo um  $\gamma_{d,\text{máx}}$  de 16,24 kN/m<sup>3</sup> com umidade ótima de 21,71%, e um  $\gamma_{d,\text{mín}}$  de 12,18 kN/m<sup>3</sup> com umidade de 16,51%. Nos resultados preliminares da pesquisa de doutorado de Neves (2025), que também coletou amostras a 2 metros de profundidade e utilizou a energia normal na compactação, foi obtido um  $\gamma_{d,\text{máx}}$  de 16,37 kN/m<sup>3</sup> com umidade ótima de 21,48% e um  $\gamma_{d,\text{mín}}$  de 14,61 kN/m<sup>3</sup> com umidade

de 16,96%. Os pontos das curvas de compactação obtidos pelos autores supracitados e os ajustes dos pontos experimentais utilizando polinômios de 3º grau estão apresentados na Figura 11.

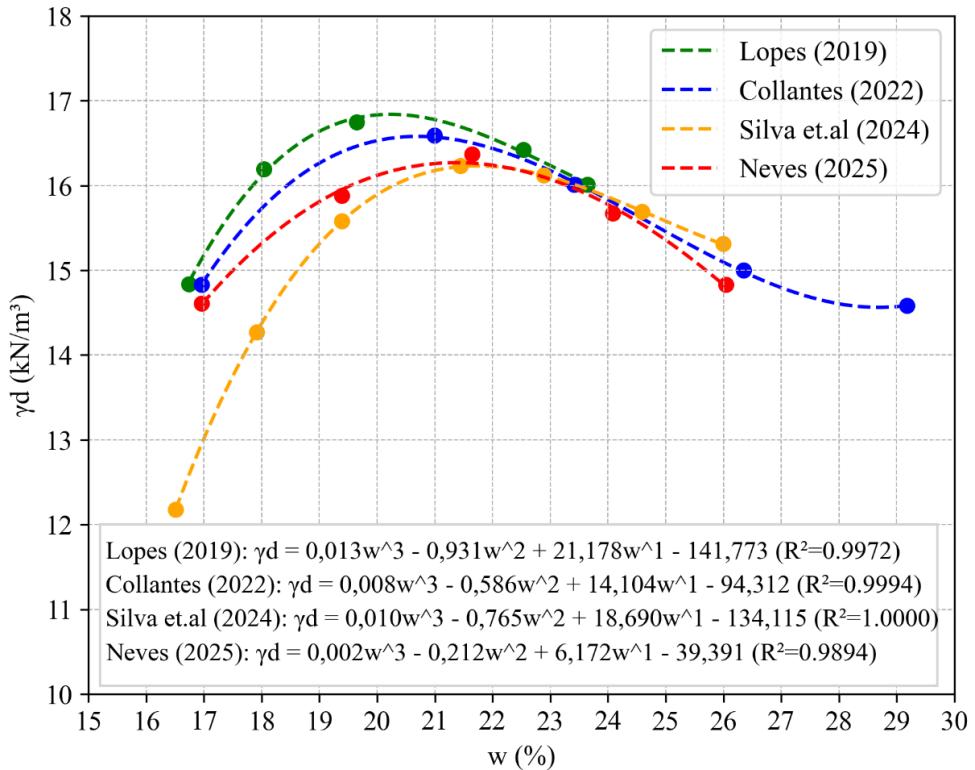


Figura 11 – Curvas de compactação do solo do Campo Experimental do PPGG/UnB com ajuste polinomial de grau 3 (Collantes, 2022; Lopes, 2019; Neves, 2025; Silva et al., 2024).

Em função da amplitude de pesos específicos alcançada no ramo seco da curva de compactação de Silva *et al.* (2024), a curva dos autores foi escolhida para a definição dos parâmetros iniciais de cada cenário, que serão explicitados na seção 3.2.

### 3.1.2. EQUIPAMENTO EXPERIMENTAL

Para construção do modelo foi utilizada uma caixa fabricada com vidro, com dimensões 1,2x0,26x0,26m. O equipamento utilizado não possui uma das faces, que funcionou como face de jusante do modelo. Os sistemas de entrada e saída de água montados para possibilitar a circulação de água no sistema serão detalhados na seção 3.2. A caixa foi posicionada sobre uma plataforma constituída de uma série de 7 blocos de concreto com 0,35m de altura com o objetivo de facilitar o processo de compactação das camadas e servir como uma base rígida o suficiente para transmitir o ruído ambiental para a barragem (Figura 12).

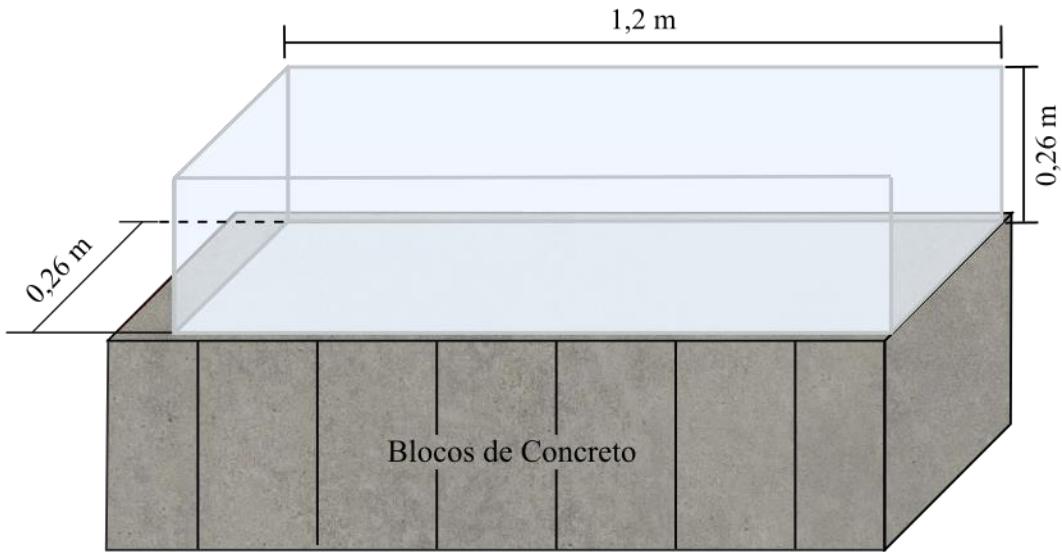


Figura 12 – Dimensões da caixa de vidro tendo por base blocos de concreto.

### 3.1.3. INSTRUMENTAÇÃO

O sensor a ser utilizado é um sismógrafo fabricado pela empresa *Raspberry Shake*, sendo constituído por um sistema composto de um microcontrolador (placa *Raspberry*) e geofones em uma caixa acrílica (Figura 13). A aquisição dos dados é feita por 3 geofones posicionados ortogonalmente, o que permite o monitoramento de ondas em três direções ortogonais. São geofones de 4,5 Hz que permitem adquirir até 100 amostras por segundo. O sistema possui a capacidade de transmissão de dados em tempo real, sendo um diferencial deste sensor em relação aos outros disponíveis no mercado. O resultado do monitoramento é expresso em três canais relacionados a cada uma das direções: EHZ, que representa as ondas captadas na direção vertical; EHN, que representa a direção norte/sul e; EHE, que representa a direção leste/oeste.



Figura 13 – Sistema *Raspberry Shake* com três geofones (RS3D).

### **3.1.4. EXTRAÇÃO DOS ATRIBUTOS DAS ONDAS**

A extração de atributos foi projetada para extrair um conjunto abrangente de características de sinais de áudio, cruciais para análises em domínios como processamento de fala, música e outras aplicações de sinais baseadas em tempo. A seleção dessas características baseou-se no trabalho de Fisher *et al.* (2017), visando fornecer uma representação robusta e significativa dos dados de áudio (Albuquerque *et al.*, 2022).

Conforme descrito pelos autores, o processo de extração de características é realizado quadro a quadro para cada canal do sinal de entrada. Para mitigar o vazamento espectral, que ocorre nas transições de quadros devido à descontinuidade do sinal, a função emprega a sobreposição de quadros. Para isso foram definidos dois parâmetros: o *frame size* (comprimento da janela de análise) e o *hop length* (deslocamento da janela de análise).

As características extraídas são divididas em duas categorias principais:

I. Características no Domínio do Tempo:

- a. Envelope de Amplitude (EA): representa a variação da amplitude instantânea do sinal ao longo do tempo;
- b. *Root-Mean-Square* (RMS): mede a intensidade média do sinal no quadro;
- c. Taxa de Cruzamento por Zero (TCZ): indica a frequência com que o sinal cruza o eixo zero, sendo um indicador de características percussivas ou da presença de ruído.

II. Características no Domínio da Frequência:

- a. Razão de Energia de Banda (REB): calcula a proporção da energia do sinal abaixo e acima de uma frequência de corte especificada;
- b. Largura de Banda Espectral (LBE): descreve a dispersão das frequências no espectro do sinal;
- c. Centroide Espectral (CE): representa o "centro de massa" do espectro de frequência, indicando a predominância de frequências mais baixas ou mais altas;
- d. Planicidade Espectral (PE): quantifica o quanto "plano" ou "pontiagudo" é o espectro, com valores mais altos indicando um espectro mais próximo de ruído branco;
- e. *Rolloff* Espectral (RE): a frequência abaixo da qual uma porcentagem especificada da energia total do espectro está contida (neste caso, 85%), útil para distinguir entre sons vocais e não-vocais;

- f. Coeficientes Cepstrais de Frequência Mel (MFCCs): foram extraídos MFCCs, que são amplamente utilizados em reconhecimento de fala e música por sua capacidade de representar as características timbrais de um som. Além dos 13 MFCCs brutos, foram calculadas suas primeiras e segundas derivadas, que representam as variações temporais desses coeficientes, fornecendo informações sobre a dinâmica do sinal.

### 3.2. METODOLOGIA

A metodologia da presente dissertação foi dividida em duas etapas, exibidas no fluxograma da Figura 14.

Na Etapa 1, foi feita a escolha de um parâmetro intermediário (PI) que possa ser relacionado com o carreamento das partículas finas do solo durante um processo de *piping* e detectado durante o monitoramento sísmico. Foram definidas duas variáveis iniciais, o teor de umidade ( $\theta$ ) e o índice de vazios ( $e$ ), avaliadas em amostras de areia com diferentes características. Foram montados 3 cenários, no primeiro foi utilizado uma amostra de areia grossa seca, no segundo uma amostra de areia fina úmida e no terceiro uma amostra de areia fina seca. Os cenários foram montados em células acrílicas, os sensores foram posicionados sobre as células e o monitoramento foi feito durante 2 horas. Os dados monitorados foram pré-processados utilizando o *software* gratuito *Swarm*, desenvolvido pelo Instituto de Pesquisas Geológicas dos Estados Unidos (*United States Geological Survey - USGS*). Trata-se de uma aplicação desenvolvida para analisar dados sísmicos, funcionando com fontes estáticas e dinâmicas, sendo possível utilizá-lo para analisar dados em tempo real. Os dados foram analisados visualmente, sendo definido o parâmetro intermediário com base nos resultados observados e na literatura.

Na Etapa 2, foram montados cenários de monitoramento de fluxo em uma simulação de *piping* em um modelo de barragem em escala de laboratório. Foram definidos cinco cenários estáticos e um cenário dinâmico. Em todos os cenários, o *piping* foi induzido no barramento seguindo a prática comumente adotada na literatura, com a inserção de um tubo ligando o reservatório de montante ao talude de jusante da barragem durante o processo de construção da barragem, induzindo uma descontinuidade. Durante o enchimento do reservatório o tubo foi mantido selado de forma a não permitir a passagem de água, o monitoramento foi iniciado quando se permitiu o fluxo de água pela descontinuidade. As condições de contorno do ensaio foram mantidas constantes em todos os cenários: 1) O nível de água do reservatório de montante foi mantido constante durante o monitoramento e; 2) No início do ensaio há uma

descontinuidade, induzida pela introdução de um tubo no corpo da barragem, com diâmetro de 8 mm.

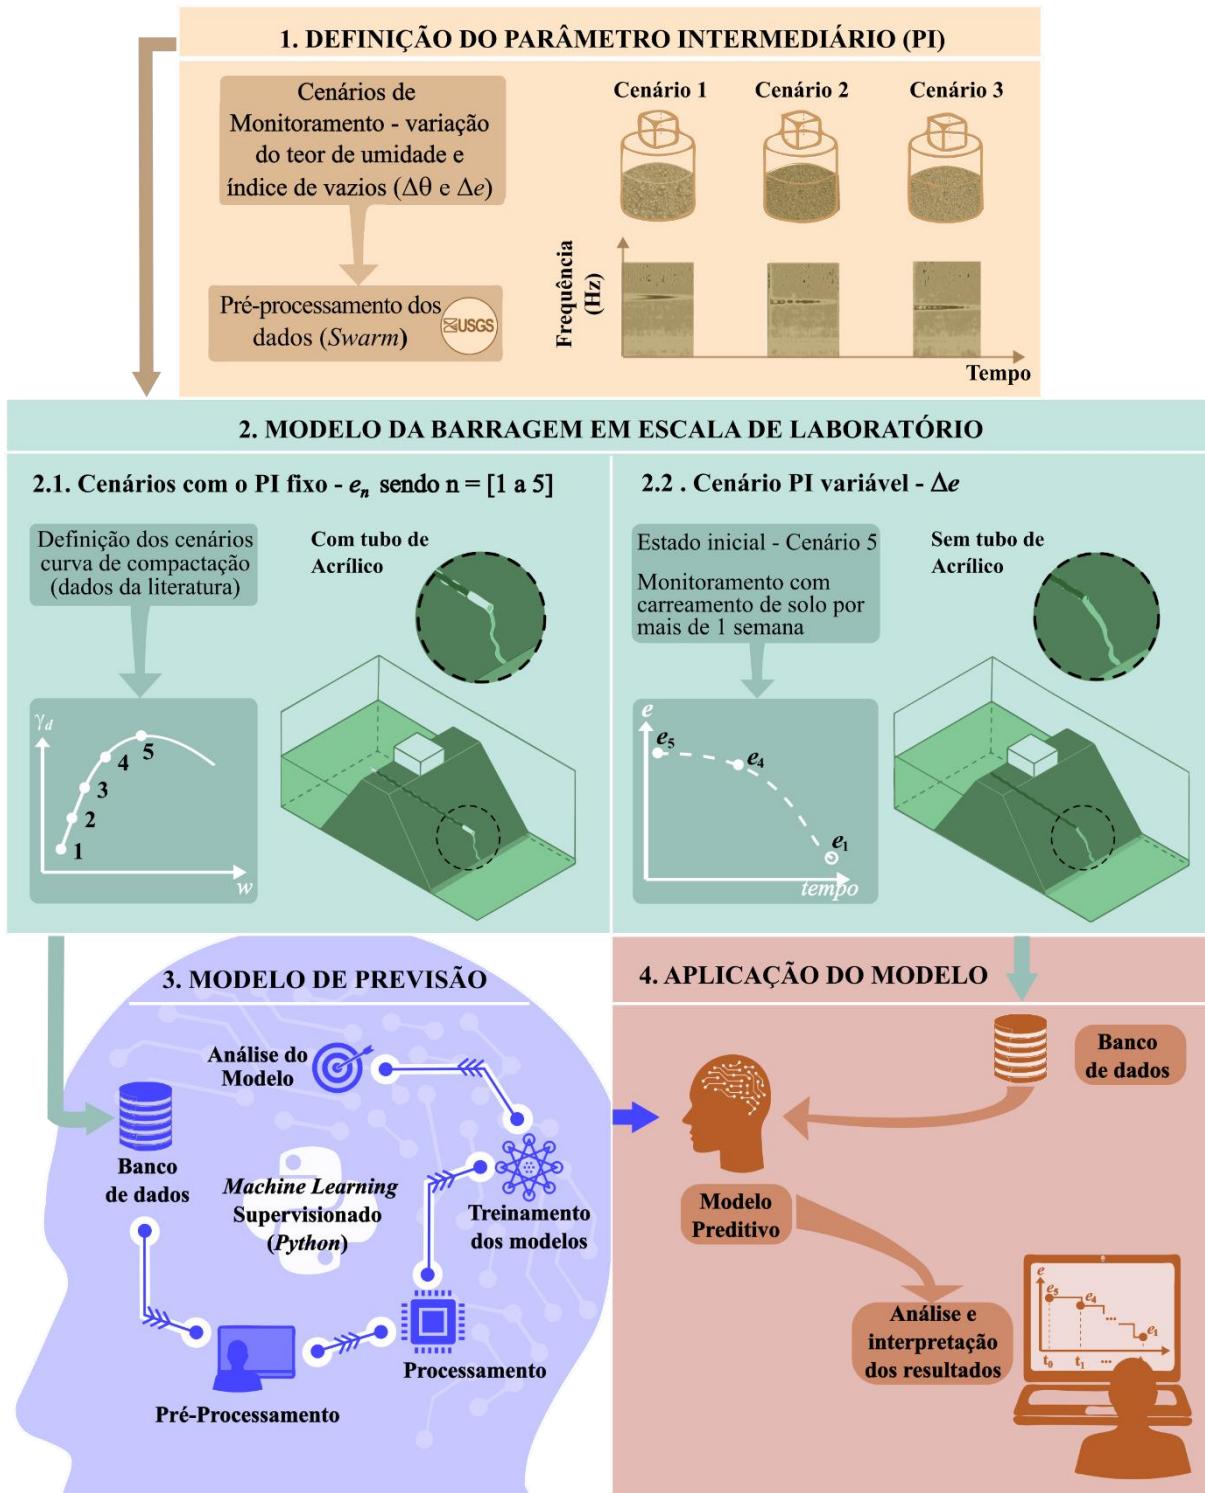


Figura 14 – Fluxograma metodológico realizado nesta pesquisa.

Nos cenários estáticos foi inserido um tubo de acrílico com diâmetro interno de 8mm durante a compactação. Em todos eles o tubo não foi retirado durante o monitoramento, criando um caminho preferencial de fluxo de água do reservatório por uma descontinuidade no corpo do barramento cujo diâmetro não sofre alteração com o tempo, mantendo as duas condições de contorno constantes (Figura 15).

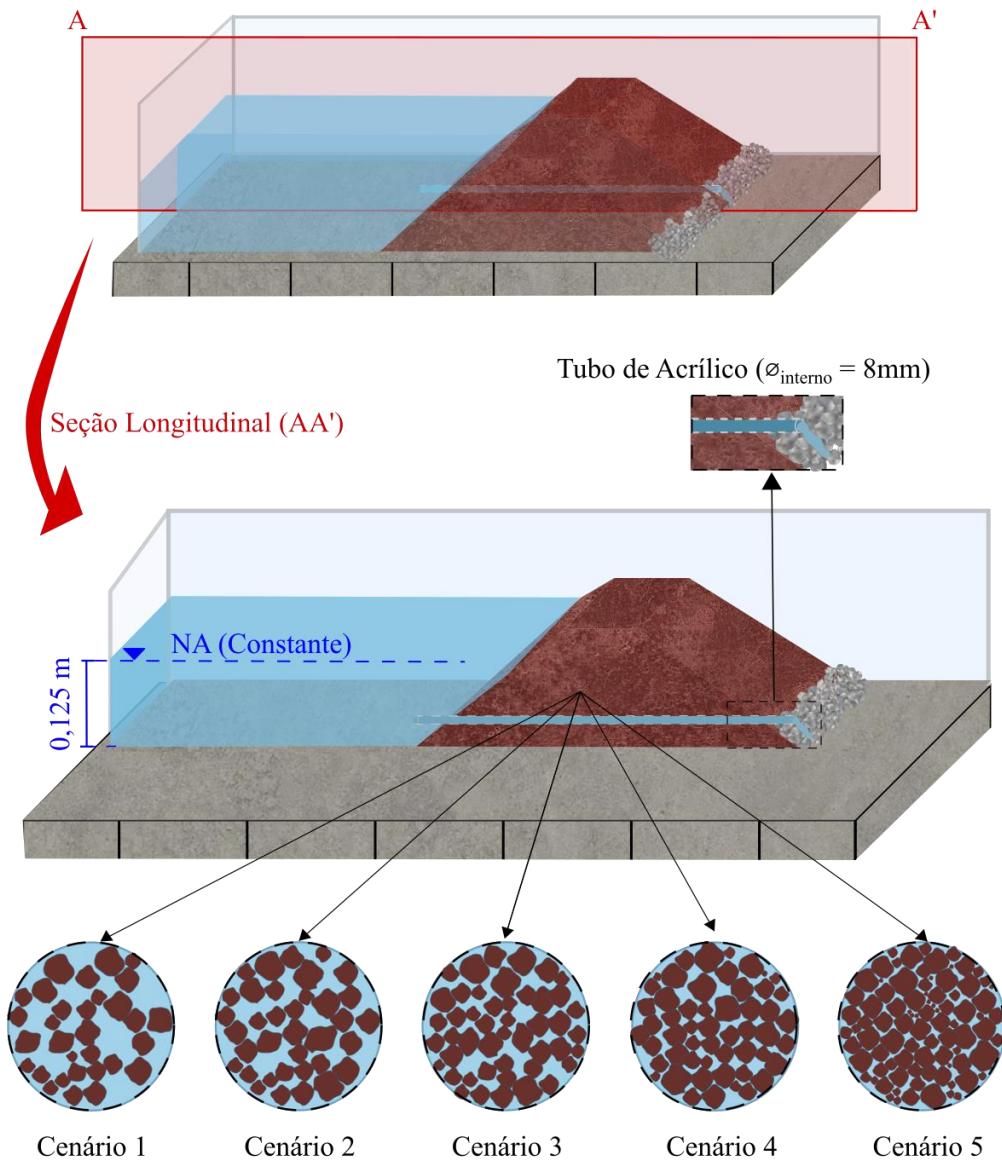


Figura 15 – Condições de contorno e inicial de cada um dos cenários estáticos.

Utilizando o intervalo entre o peso específico seco máximo e mínimo obtidos por Silva *et al.* (2024), foram definidos 5 pesos específicos como condição inicial de cada um dos cenários estáticos, conforme apresentado na Tabela 1. O Cenário 5 foi utilizado tanto como condição inicial do cenário estático, para caracterizar o comportamento inicial, como do cenário dinâmico, para que a variação do índice de vazios causada pelo carreamento das partículas faça

com que o índice de vazios equivalente do meio diminua, passando pelos índices de vazios simulados nos cenários 4, 3, 2 e 1.

Tabela 1 - Condição inicial dos cenários estáticos e dinâmico.

Cenário	$\gamma_d$ (kN/m <sup>3</sup> )	e	w (%)
1	12,180	1,17	16,51
2	13,195	1,01	17,12
3	14,210	0,86	17,87
4	15,225	0,74	18,90
5	16,230	0,63	21,46

Onde,  $\gamma_d$  é o peso específico seco, e é o índice de vazios, calculado a partir da equação (12), e w é a umidade do material.

$$e = \frac{G_s \gamma_w}{\gamma_d} - 1 \quad (12)$$

Onde,  $\gamma_w$  é o peso específico da água (9,81 kN/m<sup>3</sup>) e  $G_s$  é o peso específico relativo de sólidos do solo. O valor de  $G_s$  utilizado foi obtido a partir do trabalho de doutorado em andamento de Neves (2025), sendo igual a 2,7.

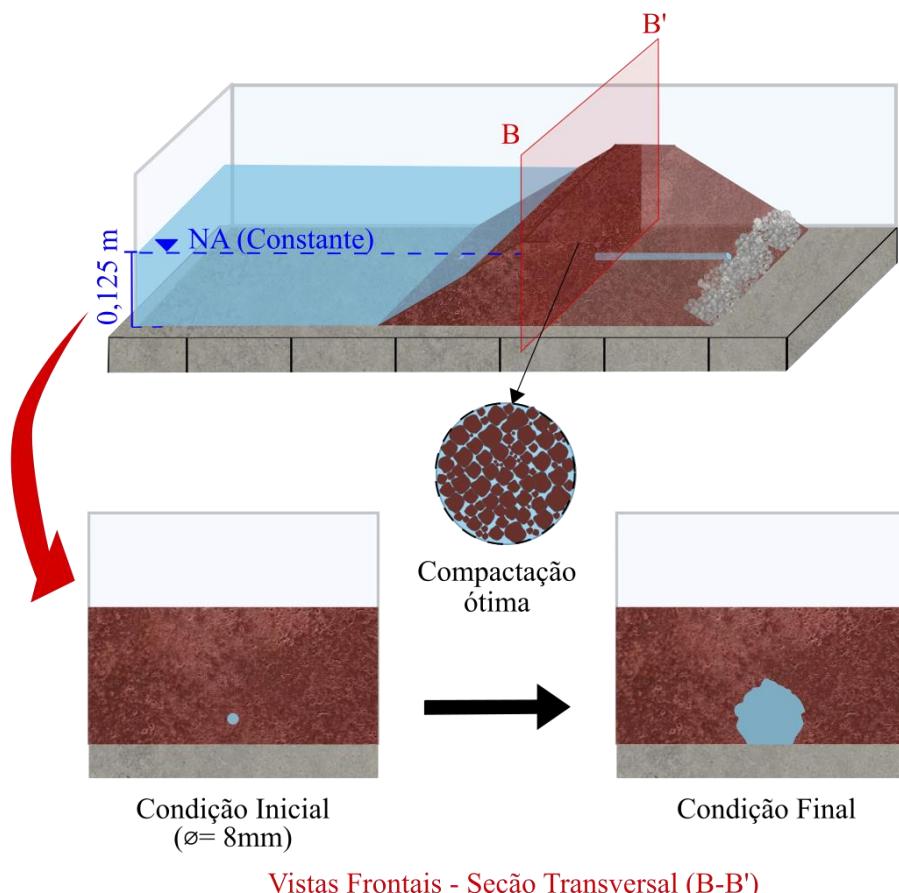


Figura 16 – Condições de contorno e condição inicial/final do cenário dinâmico.

No cenário dinâmico foi inserido um tubo maciço de aço com diâmetro externo de 8mm no interior da barragem durante a compactação. Neste cenário o tubo foi retirado no início do monitoramento e permitiu-se que o fluxo de água no interior da descontinuidade carregasse as partículas finas do material, simulando a ocorrência de *piping* no modelo (Figura 16).

### 3.2.1. DIMENSÕES E MONTAGEM DO MODELO EM LABORATÓRIO

As dimensões do modelo construído foram arbitradas de forma a comportar o sensor na crista sem a necessidade de adaptações, garantindo um bom acoplamento do sensor à crista. O modelo possuiu 0,15m de altura com taludes de 30° e base de 0,63m. A lâmina d'água foi mantida com uma altura máxima de 0,125m (Figura 17).

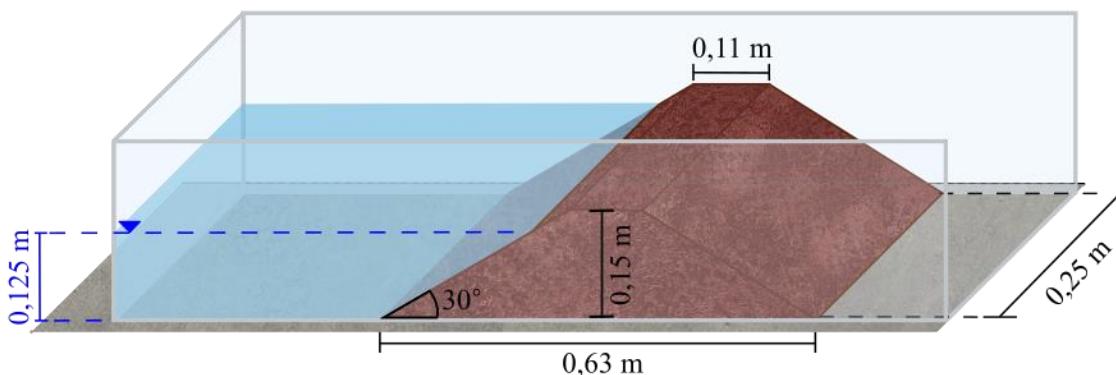
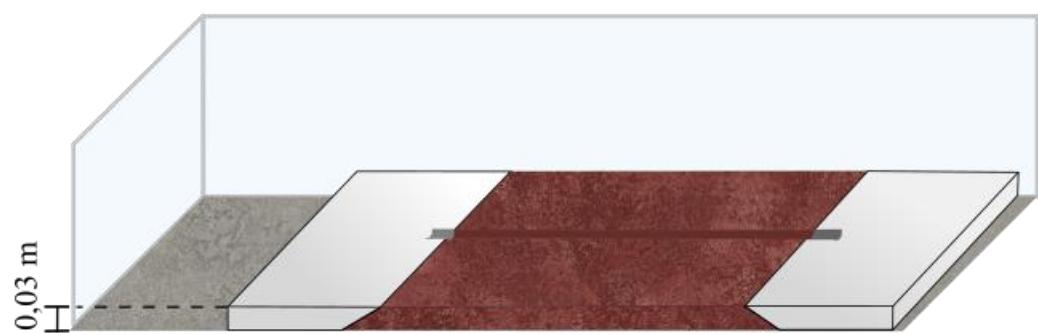


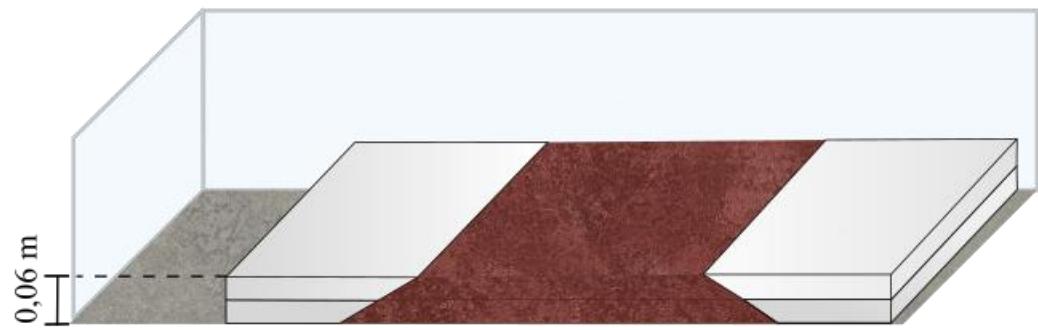
Figura 17 – Dimensões do modelo de barragem.

A montagem do modelo foi feita em cinco camadas de 3 cm para facilitar a compactação do material. Para cada camada, com base nas condições iniciais de cada cenário indicadas na Tabela 1, foi calculada a quantidade de solo seco e água necessários para atingir o peso específico e, portanto, o índice de vazios estipulado. As quantidades calculadas foram pesadas e separadas, a homogeneização do material foi feita com o auxílio de uma betoneira em função da quantidade elevada de material, principalmente nas primeiras camadas.

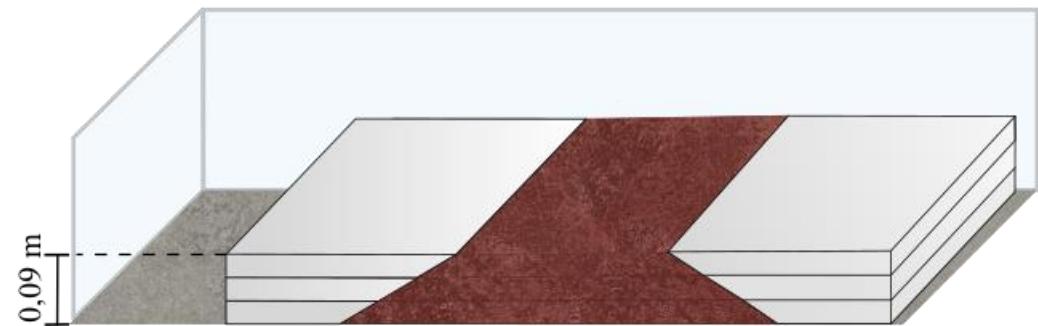
A compactação do material foi feita utilizando um soquete pequeno, a energia de compactação em cada camada foi distribuída com o auxílio de uma série de cinco apoios feitos de madeira, cujas dimensões eram compatíveis com o tamanho de cada camada. O controle da compactação foi feito por meio da verificação da altura da camada durante o processo de compactação. Para isso, utilizou-se um desenho de referência da barragem, feito na face externa do vidro, e estruturas auxiliares elaboradas para delimitar as dimensões da barragem durante a construção das camadas, conforme apresentado na Figura 18.



(a)



(b)



(c)



(d)

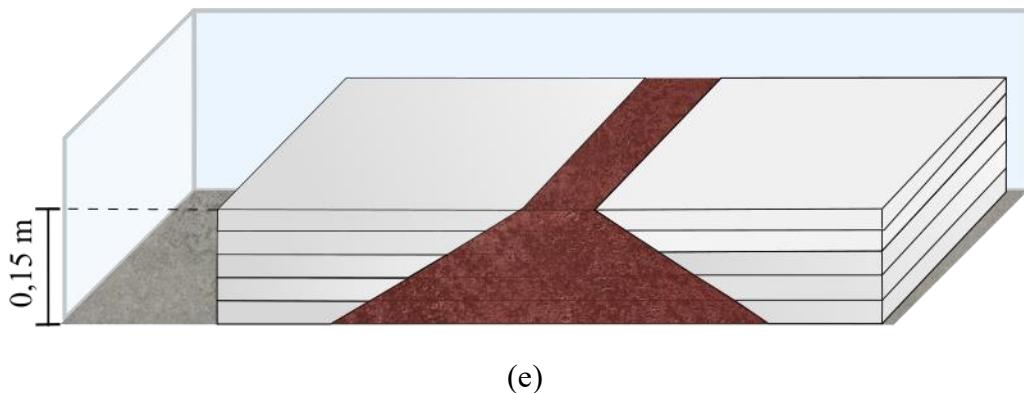


Figura 18 – Esquema de montagem e compactação das camadas do modelo de barragem: (a) primeira camada, com o sulco para inserção do tubo; (b) segunda camada; (c) terceira camada; (d) quarta camada e; (e) quinta camada.

Após a compactação de cada camada, foi feita a escarificação do material e, em seguida o material da camada subsequente foi depositado e compactado. No topo da primeira camada da compactação, foi feito um sulco para receber o tubo que simulou a descontinuidade no barramento (Figura 18a).

### 3.2.2. CONFIGURAÇÃO DO ENSAIO

A Figura 19 apresenta a configuração do ensaio com os sistemas de entrada e saída de água, montados para permitir a circulação de água no sistema.

Para manter o nível do reservatório constante mesmo com o aumento do diâmetro da descontinuidade no cenário dinâmico, foram construídos dois sistemas de entrada de água. No primeiro, a água da rede de abastecimento alimentou um reservatório cujo nível foi mantido constante com o auxílio de uma válvula controladora de nível automática. Na saída do reservatório foi instalado um registro e um sistema de tubos com diâmetro de  $3/4"$  ligando-o ao reservatório de água da barragem, cujo nível foi mantido constante com o auxílio de uma válvula controladora de nível com diâmetro compatível com a tubulação instalada. No segundo, a rede de abastecimento foi ligada diretamente ao reservatório da barragem, utilizando um sistema de tubos com diâmetro de  $1/2"$ . O nível de água no reservatório da barragem foi mantido constante com o uso de outra válvula controladora de nível.

O sistema de saída de água foi projetado para comportar um grande volume de água passando pelo corpo do barramento. Para isso, foi utilizada uma caixa de acrílico a partir da qual foi instalada uma tubulação com 50 mm de diâmetro até o ralo de captação de água mais próximo.

Os ensaios foram monitorados por 4 horas, o horário de coleta de dados escolhido foi na janela das 1h às 5h. Como a metodologia proposta não prevê a filtragem dos ruídos, foi escolhido o horário que representa o horário com a menor quantidade de ruídos gerados pela atividade humana nas proximidades do laboratório.

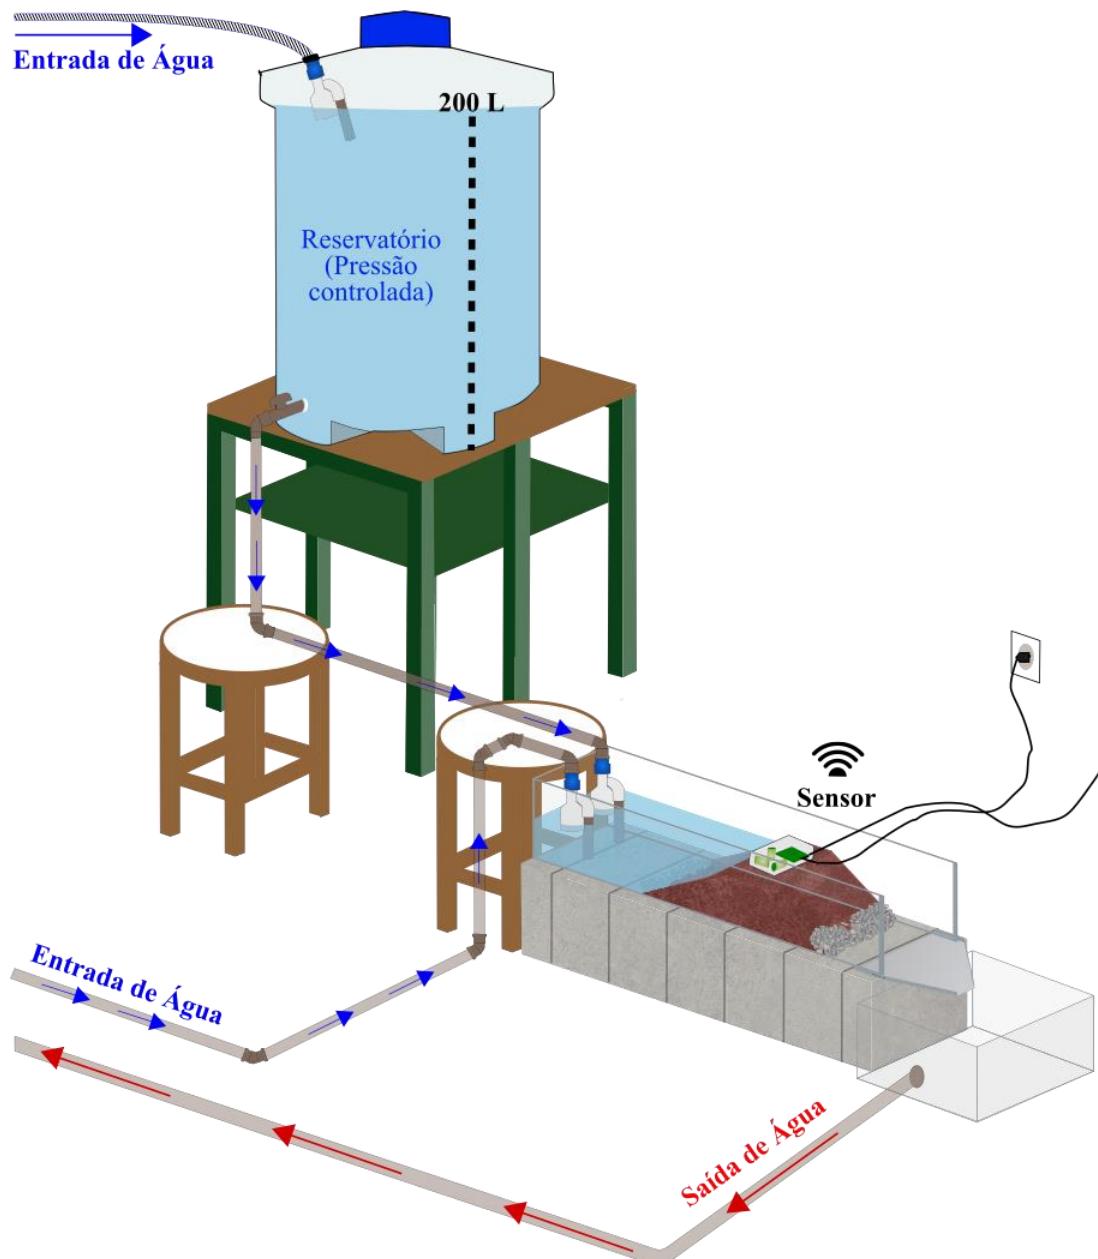


Figura 19 – Sistema de monitoramento para os cenários estáticos e dinâmicos da barragem em escala de laboratório

### 3.2.3. MODELOS DE IA E ANÁLISE DOS RESULTADOS

Os cenários de monitoramento estático foram utilizados como dados de entrada dos modelos supervisionados de *Machine Learning* de classificação e de regressão. Inicialmente

foram utilizadas todas as componentes (EHZ, EHN e EHE) para gerar os modelos de previsão. Os dados foram pré-processados por meio da extração dos atributos, divididos entre teste e treinamento usando uma proporção de 20% dos dados para teste e 80% para treinamento dos algoritmos. Foi aplicada a validação cruzada utilizando o *10-fold cross validation* nos dados de treinamento. Essa é uma técnica que avalia o desempenho do modelo de forma mais precisa, para isso o conjunto de treinamento é dividido em 10 partes e, para cada rodada de validação, 9 partes são usadas para treinar o modelo e a parte restante é utilizada para avaliar o desempenho. O processo é repetido 10 vezes, alterando o conjunto utilizado para avaliar o desempenho, sendo apresentada a média e o desvio padrão dos resultados.

Em seguida os dados foram utilizados para treinar diferentes modelos, os modelos de classificação incluíram, *SGD Linear*, *Logistic Regression*, *k-Nearest Neighbors*, *Gaussian Naïve Bayes*, *Decision Tree*, *Random Forest*, *Support Vector Machine* e *Multilayer Perceptron* (MLP), enquanto os modelos de regressão incluíram o *Random Forest Regressor* e o *Support Vector Regression*. Os modelos foram utilizados com suas configurações padrão, no caso do MLP foi utilizada uma arquitetura com 4 camadas de 40 neurônios cada, a função de ativação “relu”, um parâmetro alpha de 0,001. O alpha é um parâmetro para o termo de regularização, também conhecido como termo de penalidade, que combate o *overfitting* restringindo o tamanho dos pesos. Aumentar o alfa pode corrigir a alta variância (um sinal de *overfitting*), incentivando pesos menores, resultando em um gráfico de limite de decisão que aparece com curvaturas menores. Da mesma forma, diminuir o alfa pode corrigir o alto viés (um sinal de *underfitting*), incentivando pesos maiores, potencialmente resultando em um limite de decisão mais complicado. Os resultados das métricas de cada algoritmo foi avaliada e aquele com as melhores métricas de desempenho foi selecionado como modelo preditivo.

Os dados do monitoramento dinâmico foram então utilizados como dados de entrada do modelo preditivo calibrado com os cenários estáticos para prever a variação do parâmetro intermediário no tempo. A análise dos resultados foi pautada na análise do comportamento esperado do modelo, que deveria apresentar uma variação gradual do parâmetro intermediário, conforme a observação em laboratório das condições de carreamento do material.

## 4. RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentadas as análises e discussões dos resultados obtidos nas duas etapas propostas. Inicialmente serão apresentadas as imagens da montagem final dos cenários de cada etapa de monitoramento, em seguida serão apresentados os sismogramas e espectrogramas do monitoramento realizado. Serão discutidas as diferenças nos sismogramas, espectrogramas das etapas 1 e 2 e nos atributos de onda extraídos na etapa 2. Após a apresentação dos resultados do monitoramento estático, serão apresentados os resultados do treinamento dos algoritmos de classificação e regressão, com destaque às métricas de desempenho obtidas para os modelos e a matriz de confusão do melhor modelo, selecionado como modelo de previsão para o cenário dinâmico.

Em função da densidade elevada do material no Cenário 5, o primeiro dia de monitoramento foi utilizado como resultado do cenário estático, sendo assumido que houve pouco ou nenhum carreamento de material. O monitoramento dos dias seguintes foi considerado como cenário dinâmico, serão apresentadas as variações observadas em laboratório durante o tempo monitorado e, em seguida, serão discutidos os resultados da aplicação do modelo de previsão nos dados.

### 4.1. DEFINIÇÃO DO PARÂMETRO INTERMEDIÁRIO

Os cenários de monitoramento montados estão apresentados na Figura 20, onde estão representados, da esquerda para a direita os cilindros identificados com numeração de 1 a 3. Os sensores posicionados em cada célula e as características dos materiais estão apresentados na Tabela 2. Em função do curto tempo de monitoramento dos cenários, foi escolhida uma janela de pouco mais de um minuto de duração em que foram comparadas as frequências predominantes para cada cenário de monitoramento.

Tabela 2 – Características dos materiais para determinação do parâmetro intermediário.

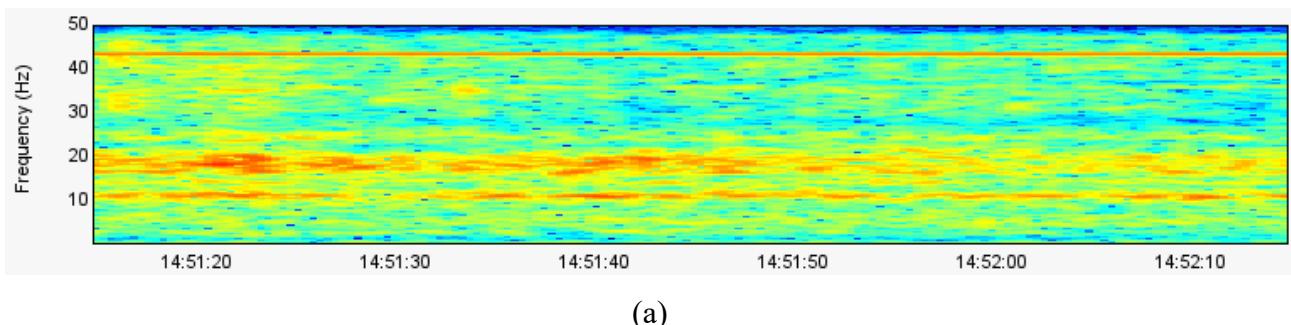
Cenário	Material	Sensor	Densidade
1	Areia grossa seca	R7D9F	1,52 g/cm <sup>3</sup>
2	Areia fina úmida	R17F9	1,09 g/cm <sup>3</sup>
3	Areia fina seca	RA0F7	1,38 g/cm <sup>3</sup>

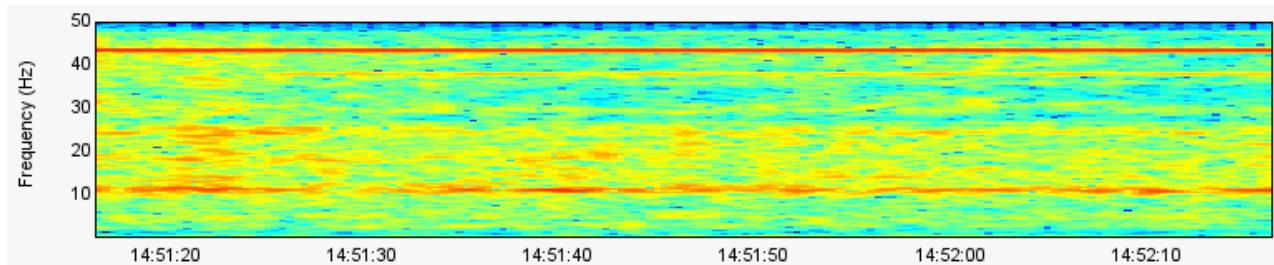


Figura 20 – Montagem dos 3 cenários de monitoramento da Etapa 1.

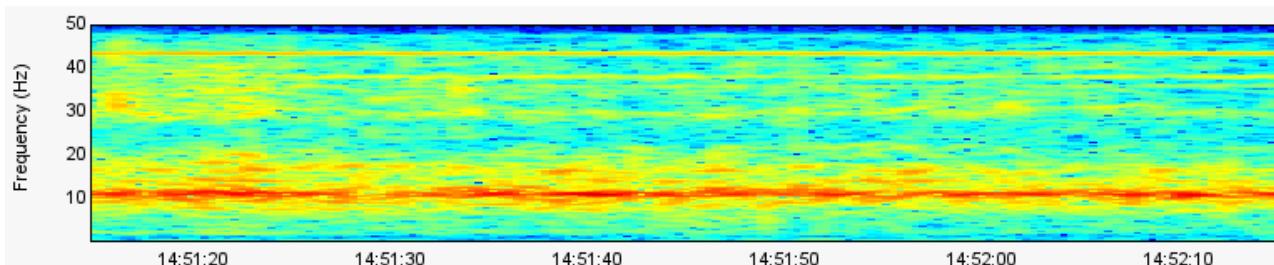
#### 4.1.1. CENÁRIO 1

Na análise dos resultados do Cenário 1, montado sobre um cilindro preenchido com areia grossa seca, é possível observar que, na componente leste-oeste (EHE) há uma predominância de frequências em torno dos 10 Hz e próximo aos 20 Hz (Figura 21a e Figura 22a). Na componente norte-sul (EHN) as frequências estão concentradas em um intervalo maior de frequência, de 10 a 30 Hz (Figura 21b e Figura 22b). Já a componente vertical (EHZ), apresenta uma faixa predominante de frequência em torno dos 10 Hz (Figura 21c e Figura 22c). Em todos os casos, há uma frequência constante próxima aos 45 Hz que apresenta um conteúdo de frequência mais pronunciado nas componentes EHE e EHN, e menos pronunciado na componente EHZ.



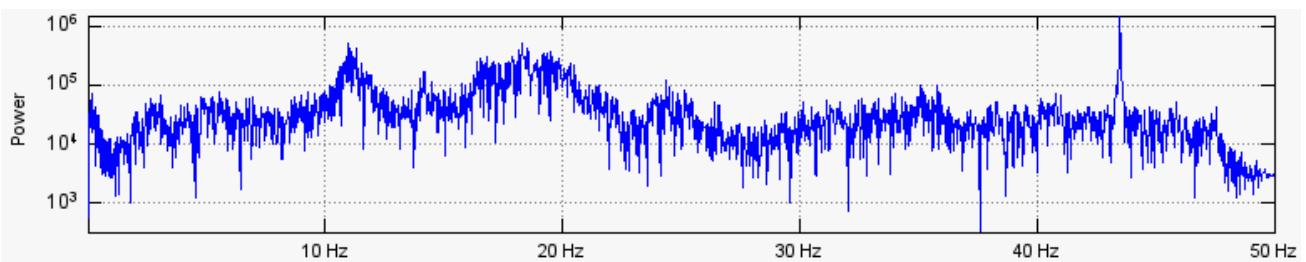


(b)

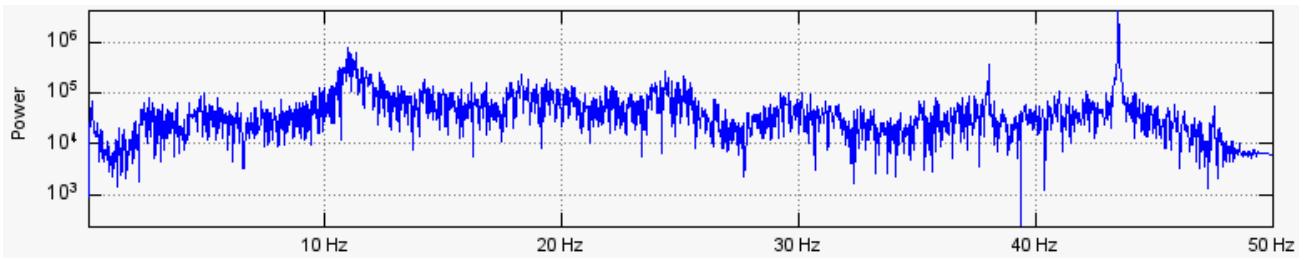


(c)

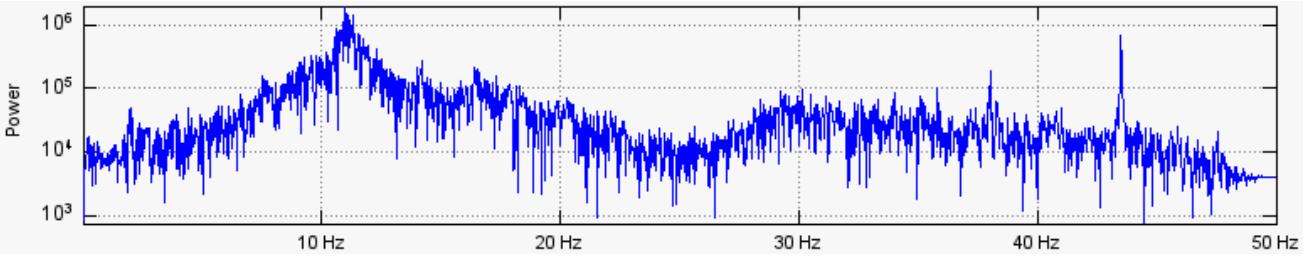
Figura 21 – Espectrograma de frequência do sensor R7D9F: (a) componente EHE; (b) componente EHN; (c) componente EHZ.



(a)



(b)



(c)

Figura 22 – Conteúdo de frequência do sensor R7D9F: (a) componente EHE; (b) componente EHN; (c) componente EHZ.

#### 4.1.2. CENÁRIO 2

Na análise dos resultados do Cenário 2, montado sobre um cilindro preenchido com areia fina úmida, é possível observar que, na componente leste-oeste (EHE) o conteúdo de frequência não é tão pronunciado, em comparação com o obtido no monitoramento do Cenário 1. Neste caso as maiores frequências ficam em torno dos 30 Hz (Figura 23a e Figura 24a). Na componente norte-sul (EHN) as frequências estão concentradas em torno de pouco mais de 10 Hz e em torno de 25 Hz (Figura 23b e Figura 24b). Já a componente vertical (EHZ), apresenta uma faixa predominante de frequência no intervalo de 10 a 20 Hz (Figura 23c e Figura 24c). Assim como foi observado no cenário 1, em todos os casos há uma frequência constante próxima aos 45 Hz, porém aqui ela apresenta um conteúdo de frequência semelhante nas três componentes.

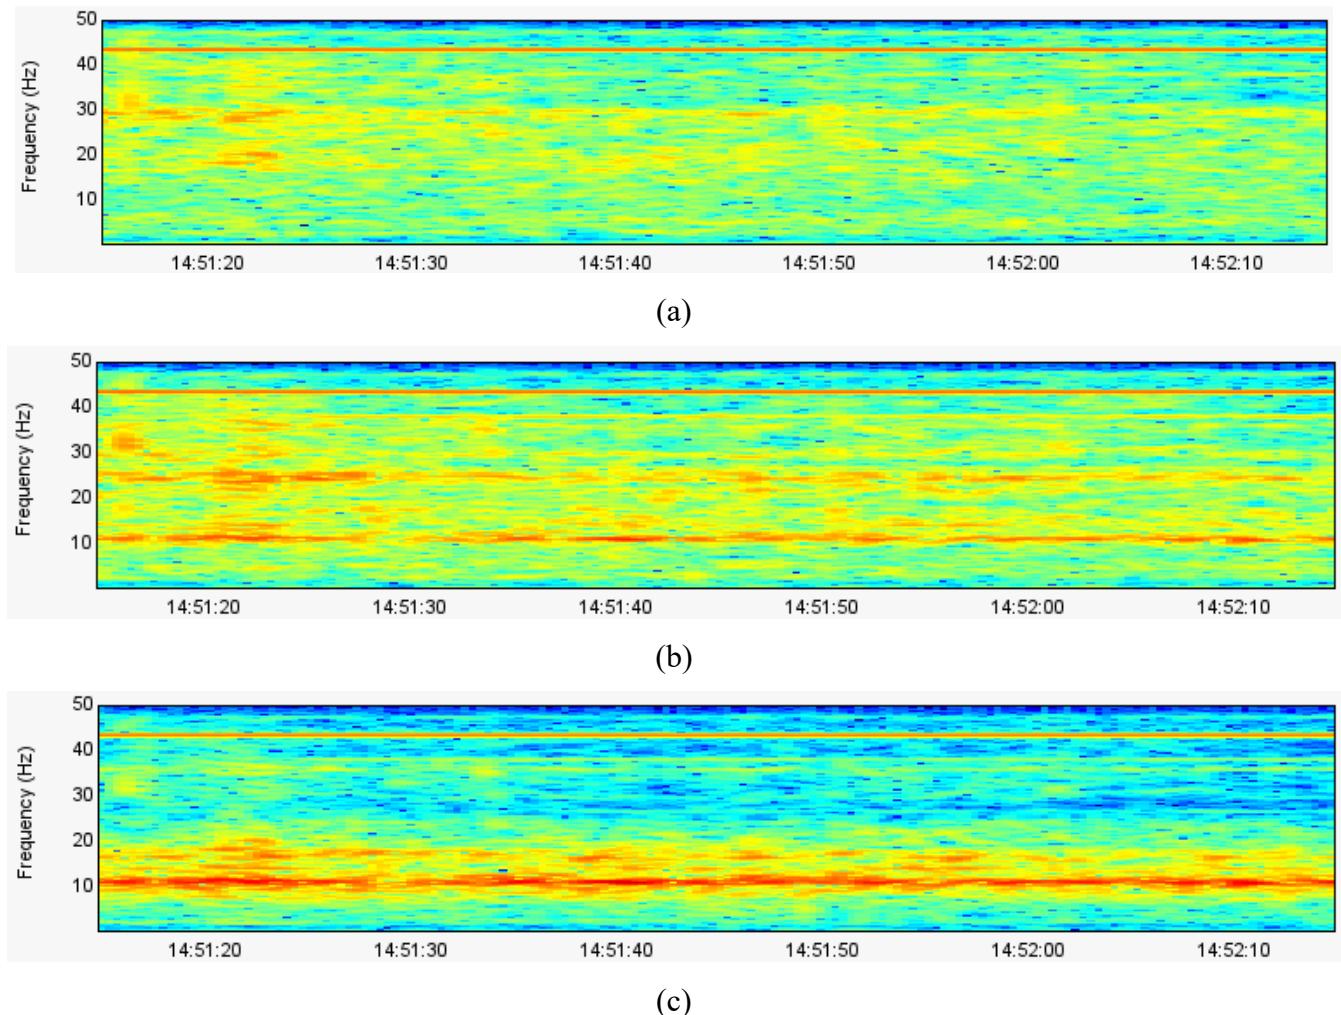


Figura 23 – Espectrogramas de frequência do sensor R17F9: (a) componente EHE; (b) componente EHN; (c) componente EHZ.

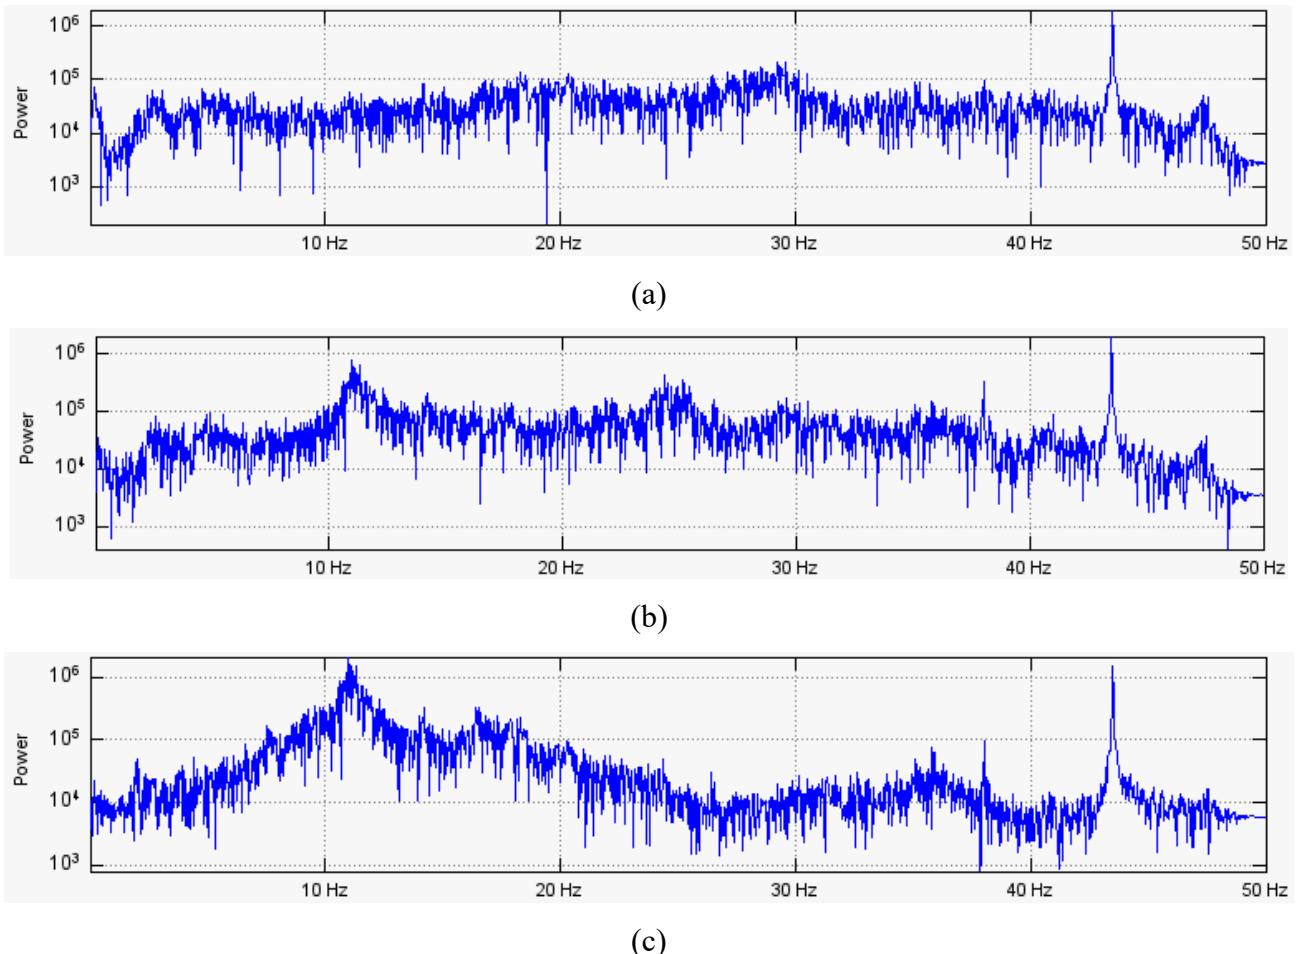


Figura 24 – Conteúdo de frequência do sensor R17F9: (a) componente EHE; (b) componente EHN; (c) componente EHZ.

#### 4.1.3. CENÁRIO 3

Na análise dos resultados do Cenário 3, montado sobre um cilindro preenchido com areia fina seca, é possível observar que, na componente leste-oeste (EHE) as frequências predominantes ficam em torno dos 20 Hz (Figura 25a e Figura 26a). Na componente norte-sul (EHN) as frequências estão concentradas um intervalo de 10 a pouco mais de 30 Hz (Figura 25b e Figura 26b). Já a componente vertical (EHZ) apresenta duas regiões predominantes de frequência: na faixa de 10 a 20 Hz e em torno de 30 Hz (Figura 25c e Figura 26c). Assim como foi observado nos Cenários 1 e 2, há uma frequência constante próxima aos 45 Hz, porém aqui ela apresenta um conteúdo de frequência semelhante nas componentes EHE e EHN e menos pronunciado na componente EHZ.

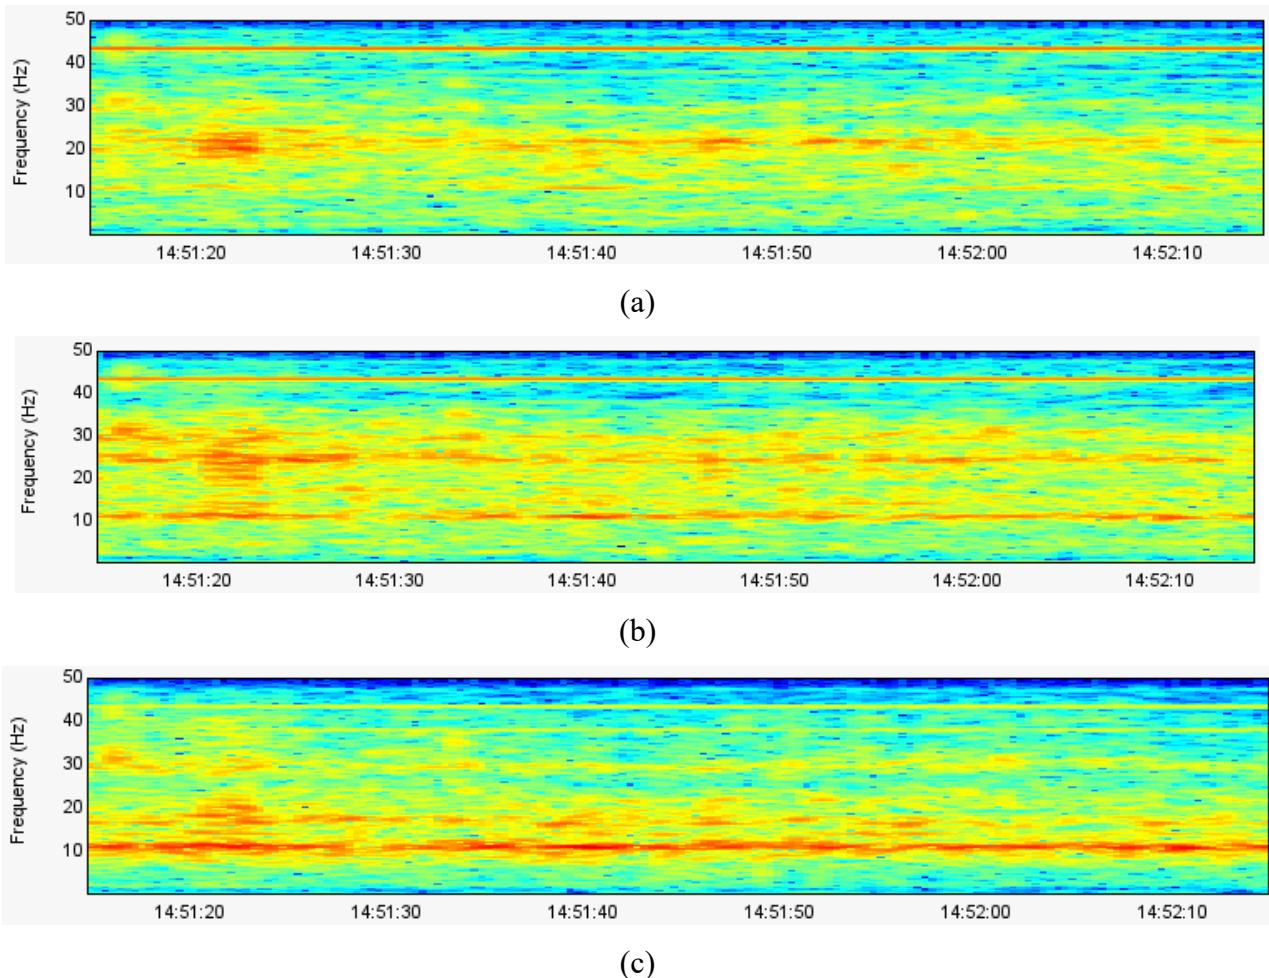
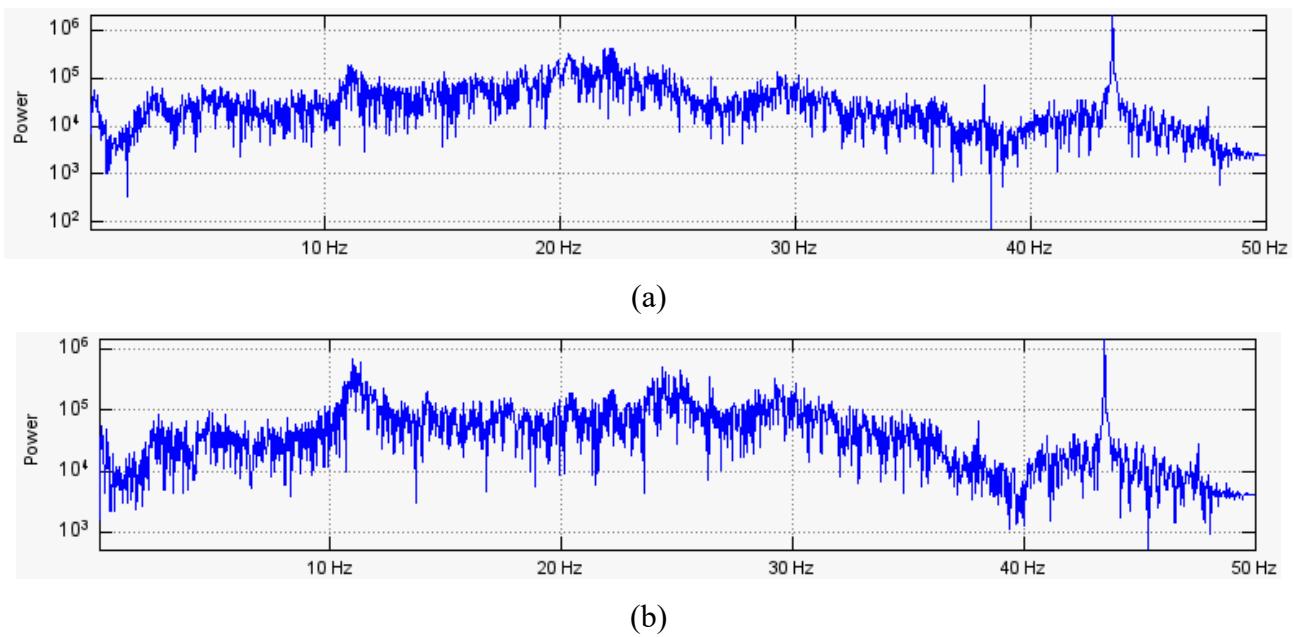
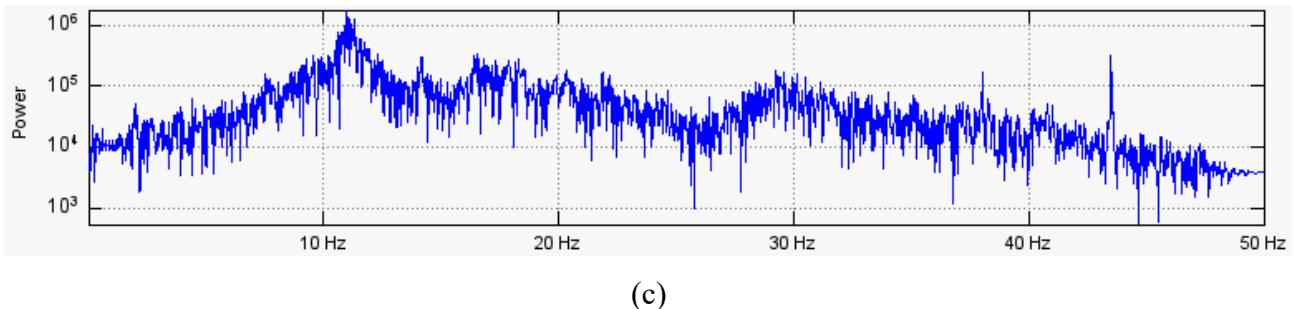


Figura 25 – Espectrogramas de frequênciade sensor RA0F7: (a) componente EHE; (b) componente EHN; (c) componente EHZ.





(c)

Figura 26 – Conteúdo de frequência do sensor RA0F7: (a) componente EHE; (b) componente EHN; (c) componente EHZ.

Como a componente vertical (EHZ) foi a que apresentou as maiores variações de comportamento, principalmente quando verificado que as frequências em torno de 45 Hz foram observadas em todos os cenários e no Cenário 3 esse efeito foi bem menos pronunciado, essa foi a componente escolhida para representar as variações observadas entre as diferentes condições de cada cenário.

Comparando a alteração da granulometria do material entre os Cenários 1 e 3, observa-se que a principal diferença entre os resultados se mostra na atenuação da frequência em torno de 45 Hz, uma vez que o comportamento observado da concentração das frequências em torno de 10 Hz é semelhante entre os dois casos. Já na comparação entre a areia fina seca e úmida, observa-se que a adição de água na amostra ajuda a atenuar os conteúdos de frequência na faixa de 20 a 40 Hz, que são menos pronunciados no Cenário 2 em comparação com o Cenário 3.

Em um processo de desenvolvimento de *piping*, como há carreamento de material fino, as alterações que ocorrem no meio estão muito relacionadas com mudanças nas características do meio, sendo melhor representada pela alteração na granulometria. Essa mudança causa alteração no índice de vazios no meio. Em função dessas observações e da verificação da capacidade do sensor de detectar essas alterações no meio, aqui representadas pela alteração na granulometria entre os Cenários 1, 2 e 3, optou-se pela escolha do índice de vazios como variável intermediária.

## 4.2. MONTAGEM E MONITORAMENTO DOS CENÁRIOS ESTÁTICOS

### 4.2.1. CENÁRIO 1

O processo de montagem está apresentado na Figura 27, onde pode ser observado o uso das estruturas auxiliares, e na Figura 28, onde está apresentada a configuração final do modelo em escala de laboratório construído para o Cenário 1. No Apêndice B está apresentada condição inicial do monitoramento deste cenário (Figura 1.B).



(a)



(b)



(c)



(d)



(e)

Figura 27 –Vista frontal das camadas durante o processo de compactação cenário 1.

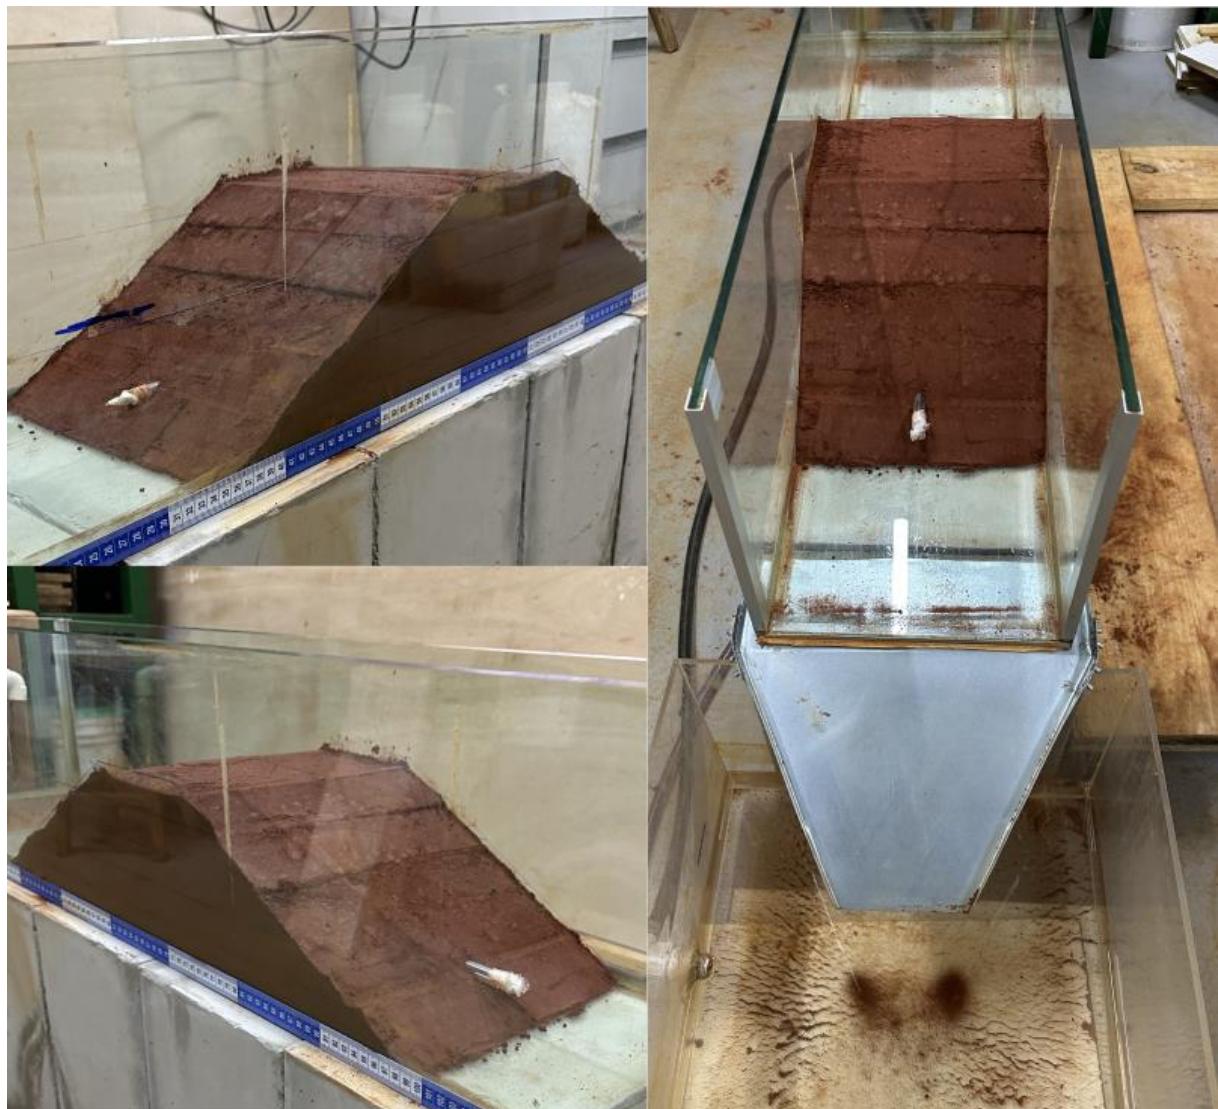


Figura 28 –Barragem montada cenário 1.

Os resultados das 4 horas de monitoramento do Cenário 1 estão apresentados na forma de sismograma (Figura 29) e espectrograma (Figura 30). Nos atributos extraídos dos dados,

apresentados na Tabela 3, que auxiliam na interpretação dos resultados observados no sismograma, observa-se uma variação média da amplitude maior para a componente EHE e muito semelhante para as componentes EHN e EHZ. No espectrograma observa-se frequências mais pronunciadas na componente EHN, enquanto as frequências nas outras componentes são menos pronunciadas. No Apêndice A, estão apresentadas as comparações dos valores de quatro atributos no tempo: o centroide espectral (Figura 1.Aa), a largura de banda espectral (Figura 2.Aa), a razão de energia de banda (Figura 3.Aa) e a taxa de cruzamento do zero (Figura 4.Aa).

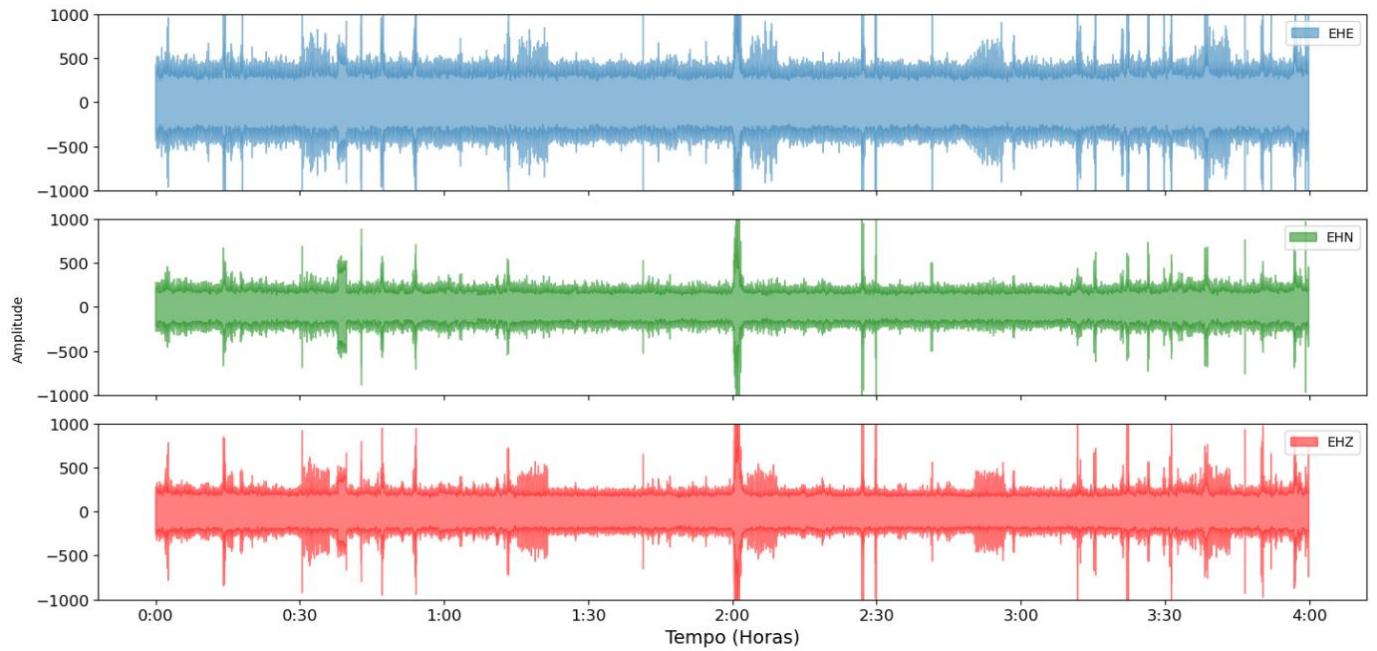


Figura 29 – Sismograma para o Cenário 1.

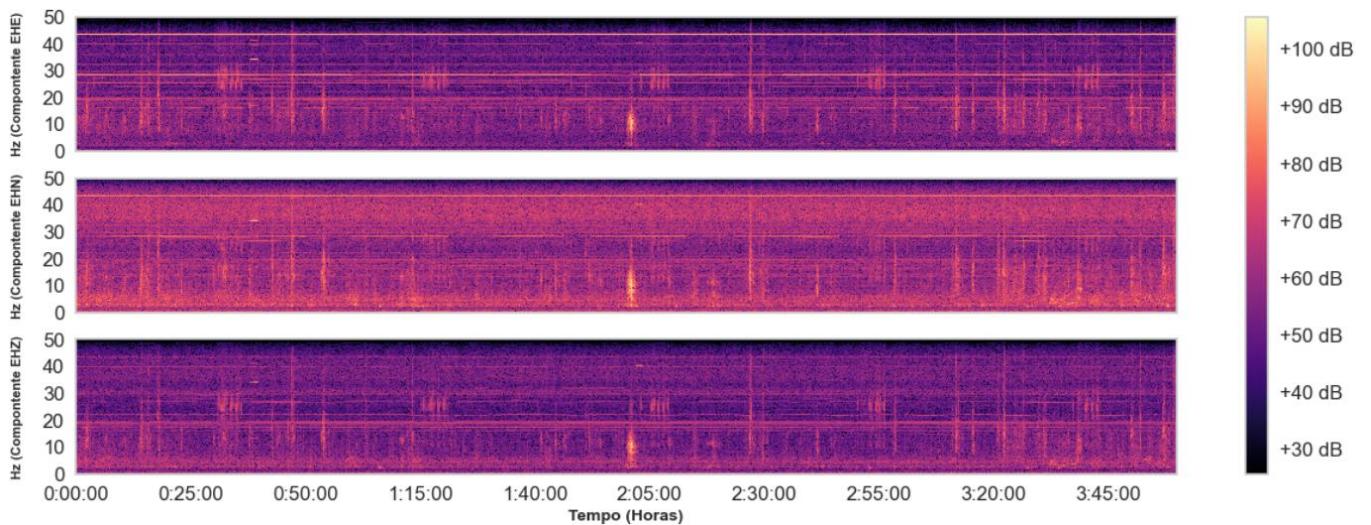


Figura 30 – Espectrograma para o Cenário 1 com os seguintes parâmetros: *frame size* (comprimento da janela de análise) = 1024 e *hop length* (deslocamento da janela de análise) = 512.

Tabela 3 – Média e desvio padrão dos atributos extraídos dos dados do Cenário 1.

Componente	EHE		EHN		EHZ	
Atributo	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão
EA	377,97	291,36	372,43	206,74	373,04	272,95
RMS	115,78	53,62	115,64	43,16	115,13	52,59
TCZ	0,654	0,082	0,65	0,08	0,66	0,08
REB	0,17	0,18	0,17	0,18	0,17	0,17
LBE	14,05	1,24	14,01	1,22	14,06	1,23
CE	22,95	1,77	22,98	1,77	22,92	1,77
PE	0,06	0,04	0,06	0,04	0,06	0,04
RE	41,9	2,61	41,9	2,44	41,81	2,68

#### 4.2.2. CENÁRIO 2

O processo de montagem está apresentado na Figura 31, onde pode ser observado o uso das estruturas auxiliares, e na Figura 32, onde está apresentada a configuração final do modelo em escala de laboratório construído para o Cenário 2. No Apêndice B está apresentada condição inicial do monitoramento deste cenário (Figura 2.B).



(a)



(b)



(c)



(d)



(e)

Figura 31 – Vista frontal das camadas durante o processo de compactação cenário 2.

Os resultados das 4 horas de monitoramento do Cenário 2 estão apresentados na forma de sismograma (Figura 33) e espectrograma (Figura 34). Nos atributos extraídos dos dados, apresentados na Tabela 4, observa-se uma variação média da amplitude menor para a componente EHN e muito semelhante para as componentes EHE e EHZ. No espectrograma observa-se que nenhuma das componentes apresentam frequências muito pronunciadas, a não ser por alguns eventos de pico, que também podem ser observados no sismograma. No Apêndice A, estão apresentadas as comparações dos valores de quatro atributos no tempo: o centroide espectral (Figura 1.Ab), a largura de banda espectral (Figura 2.Ab), a razão de energia de banda (Figura 3.Ab) e a taxa de cruzamento do zero (Figura 4.Ab).

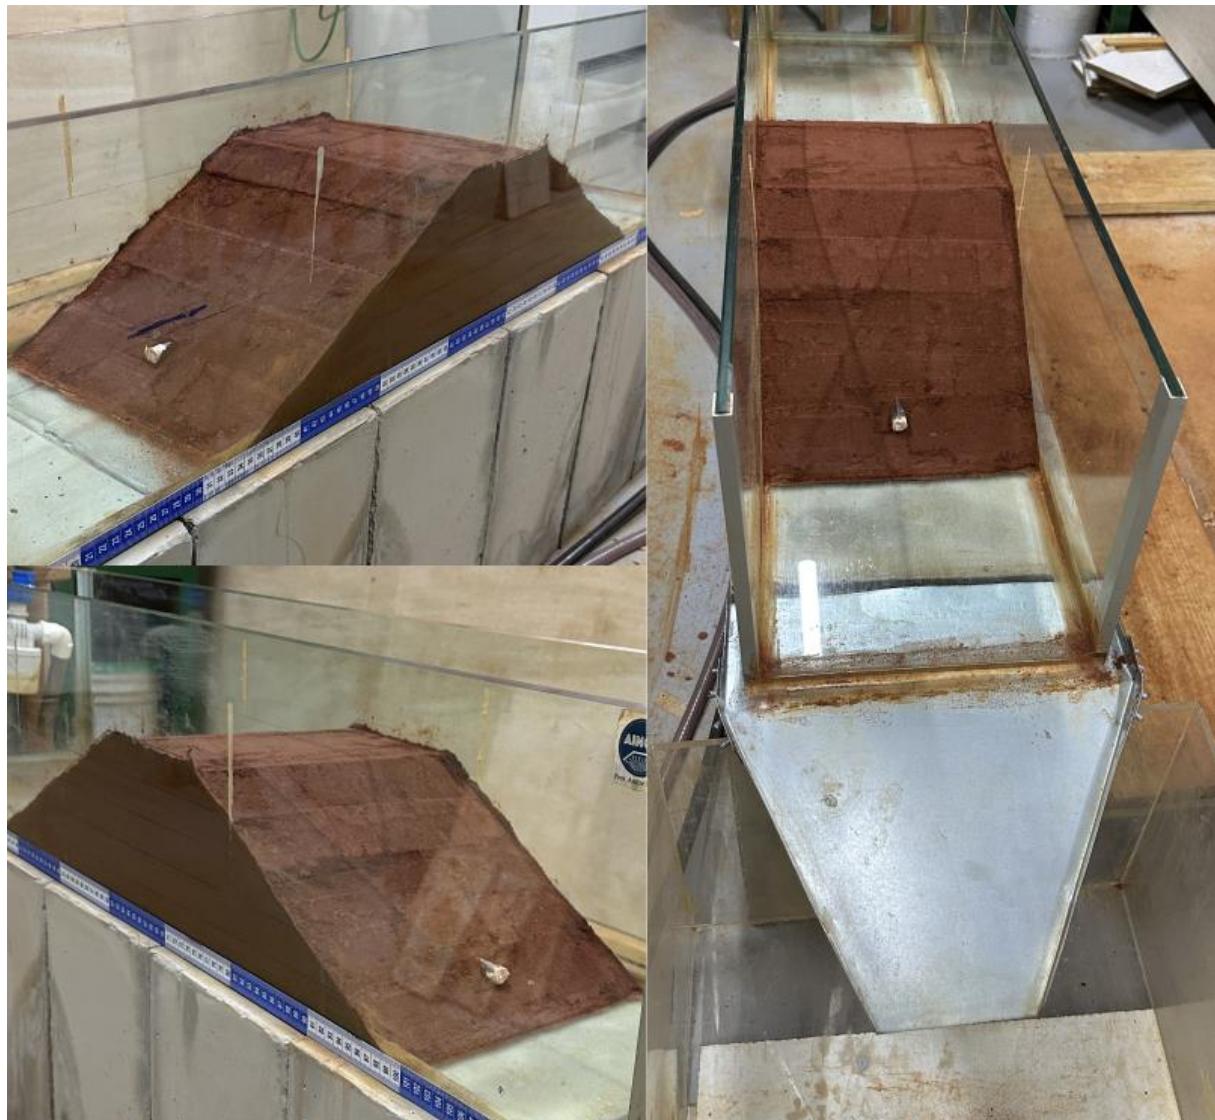


Figura 32 – Barragem montada cenário 2.

Em comparação com os resultados dos atributos extraídos para o Cenário 1, observa-se que houve um aumento no envelope de amplitude médio das componentes EHE e EHZ, enquanto a componente EHN manteve um valor semelhante ao observado no Cenário 1. O envelope de amplitude representa a variação da amplitude do sinal ao longo do tempo, indicando que, em média, as componentes EHE e EHZ apresentaram uma variação maior no Cenário 2, quando comparadas com o Cenário 1. Diferenças visuais também são possíveis de observar nos espectrogramas de frequência de ambos os cenários. Enquanto no Cenário 1 a componente EHN apresentou frequências mais pronunciadas durante todo o período de monitoramento, no Cenário 2 o mesmo comportamento não foi observado.

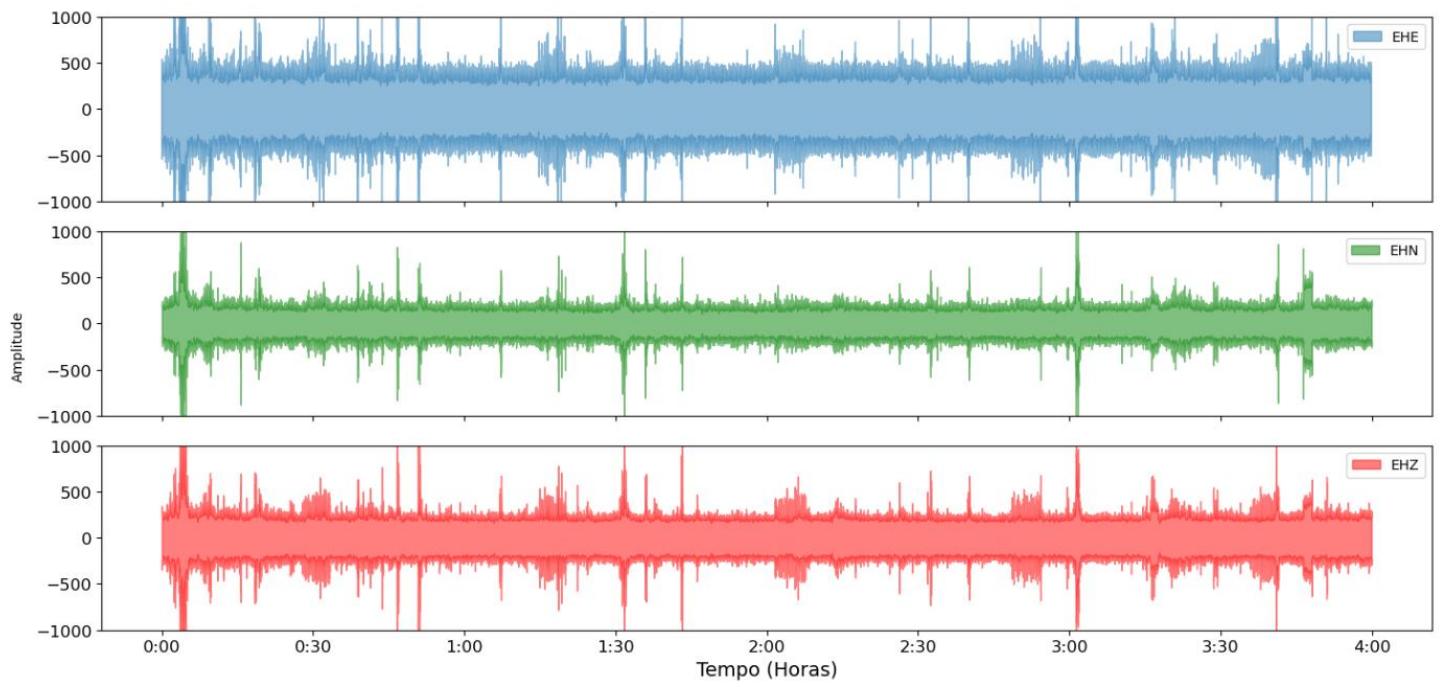


Figura 33 – Sismograma para o Cenário 2.

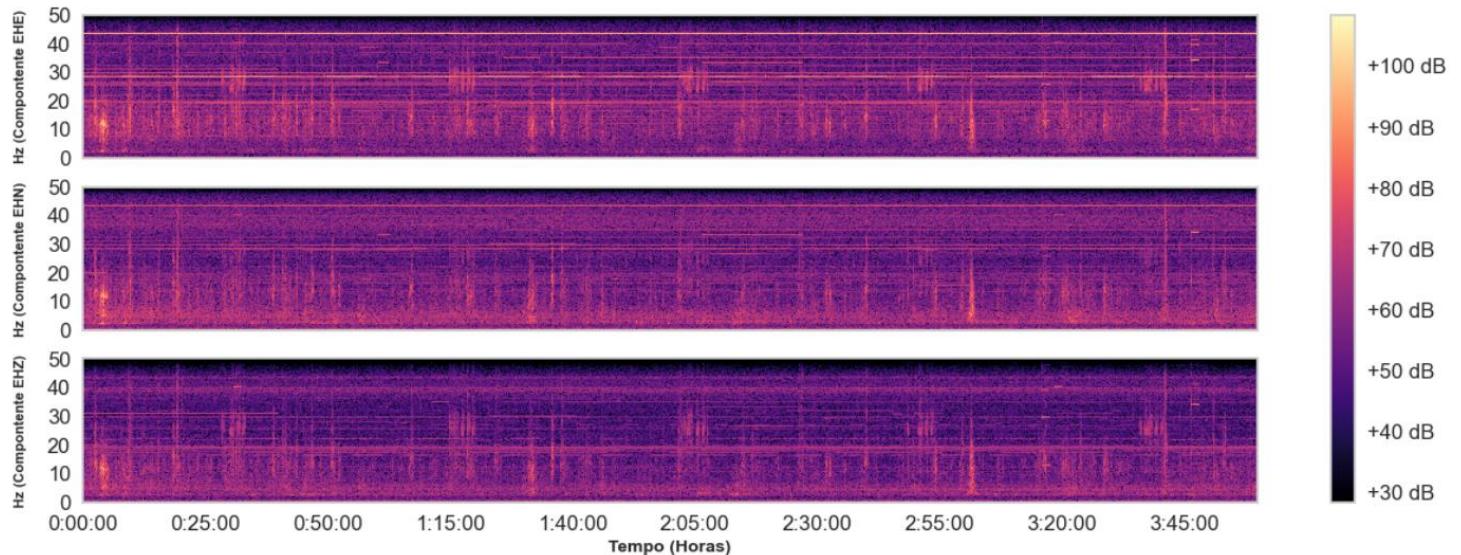


Figura 34 – Espectrograma para o Cenário 2 com os seguintes parâmetros: *frame size* (comprimento da janela de análise) = 1024 e *hop length* (deslocamento da janela de análise) = 512.

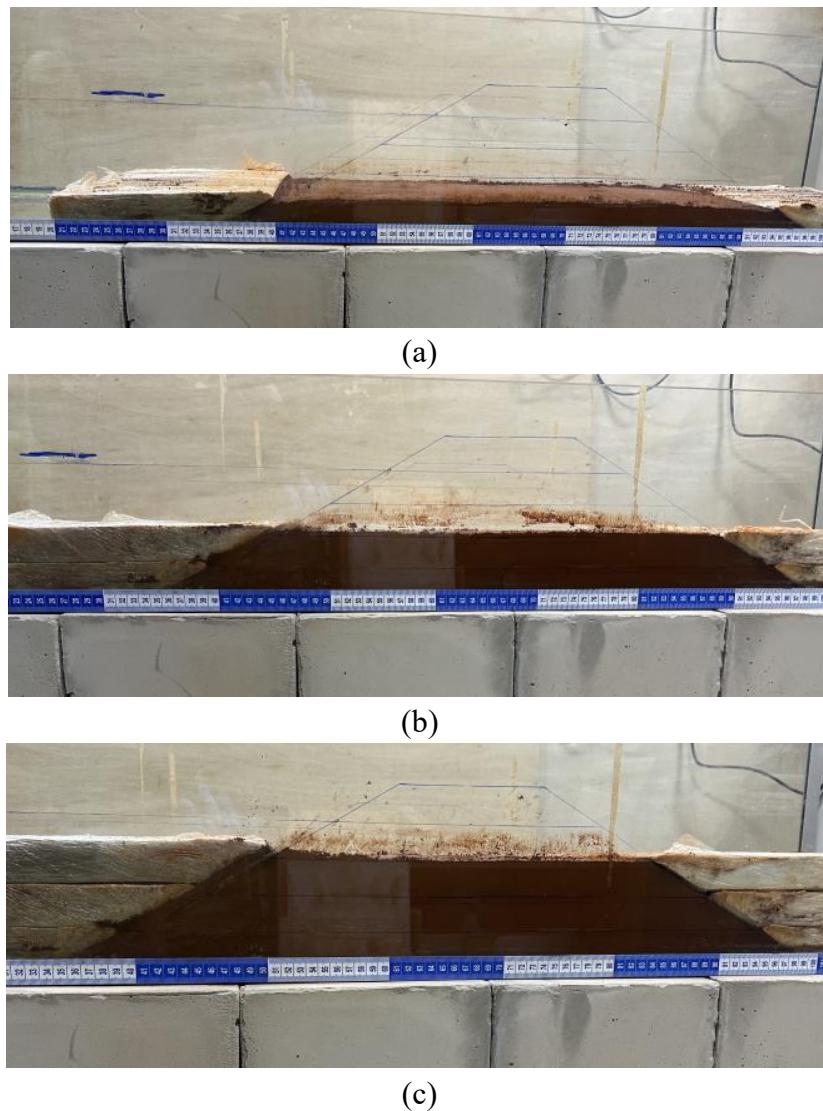
Tabela 4 – Média e desvio padrão dos atributos extraídos dos dados do Cenário 2.

Componente	EHE		EHN		EHZ	
Atributo	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão
EA	383,49	222,97	374,12	208,85	382,36	221,44
RMS	118,58	54,18	116,58	50,58	118,19	50,87
TCZ	0,64	0,09	0,64	0,09	0,64	0,09
REB	0,19	0,21	0,19	0,22	0,19	0,19

LBE	13,88	1,26	13,96	1,23	13,87	1,28
CE	22,19	2,11	22,15	2,08	22,15	2,13
PE	0,06	0,03	0,06	0,03	0,05	0,03
RE	41,12	3,07	41,3	2,86	41,08	3,12

#### 4.2.3. CENÁRIO 3

O processo de montagem está apresentado na Figura 35, onde pode ser observado o uso das estruturas auxiliares, e na Figura 36, onde está apresentada a configuração final do modelo em escala de laboratório construído para o Cenário 3. No Apêndice B está apresentada condição inicial do monitoramento deste cenário (Figura 3.B).





(d)



(e)

Figura 35 – Vista frontal das camadas durante o processo de compactação cenário 3.



Figura 36 – Barragem montada cenário 3.

Os resultados das 4 horas de monitoramento do Cenário 3 estão apresentados na forma de sismograma (Figura 37) e espectrograma (Figura 38). Nos atributos extraídos dos dados, apresentados na Tabela 5, observa-se uma variação média da amplitude muito semelhante nas três componentes. No espectrograma observa-se que nenhuma das componentes apresentam frequências muito pronunciadas, a não ser por alguns eventos de pico, que também podem ser observados no sismograma. No Apêndice A, estão apresentadas as comparações dos valores de quatro atributos no tempo: o centroide espectral (Figura 1.Ac), a largura de banda espectral (Figura 2.Ac), a razão de energia de banda (Figura 3.Ac) e a taxa de cruzamento do zero (Figura 4.Ac).

Em comparação com os resultados dos Cenários 1 e 2, observa-se que houve um aumento no envelope de amplitude médio de todas as componentes. Isso indica que, em média, as componentes EHE, EHN e EHZ apresentaram uma variação maior de amplitude no Cenário 3, quando comparadas com os Cenários 1 e 2. Em relação aos espectrogramas de frequência, os resultados obtidos no Cenário 3 são semelhantes aos obtidos no Cenário 2 e ambos diferem dos resultados obtidos no Cenário 1. Enquanto no Cenário 1 a componente EHN apresentou frequências mais pronunciadas durante todo o período de monitoramento, nos Cenários 2 e 3 o mesmo comportamento não foi observado. Ao comparar essa mesma componente nos Cenários 2 e 3 é possível observar visualmente que no Cenário 3 existe uma pequena diferença nas frequências em torno de 40 Hz, que estão mais pronunciadas no último cenário.

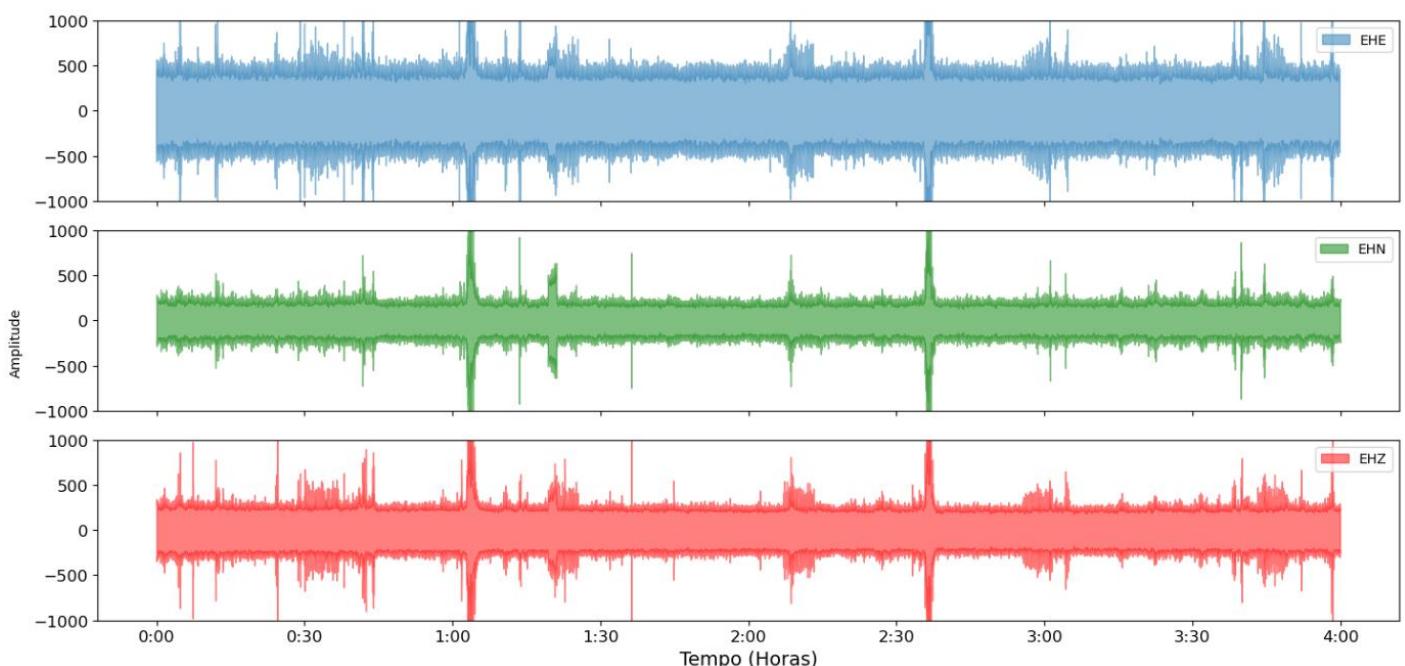


Figura 37 – Sismograma para o Cenário 3.

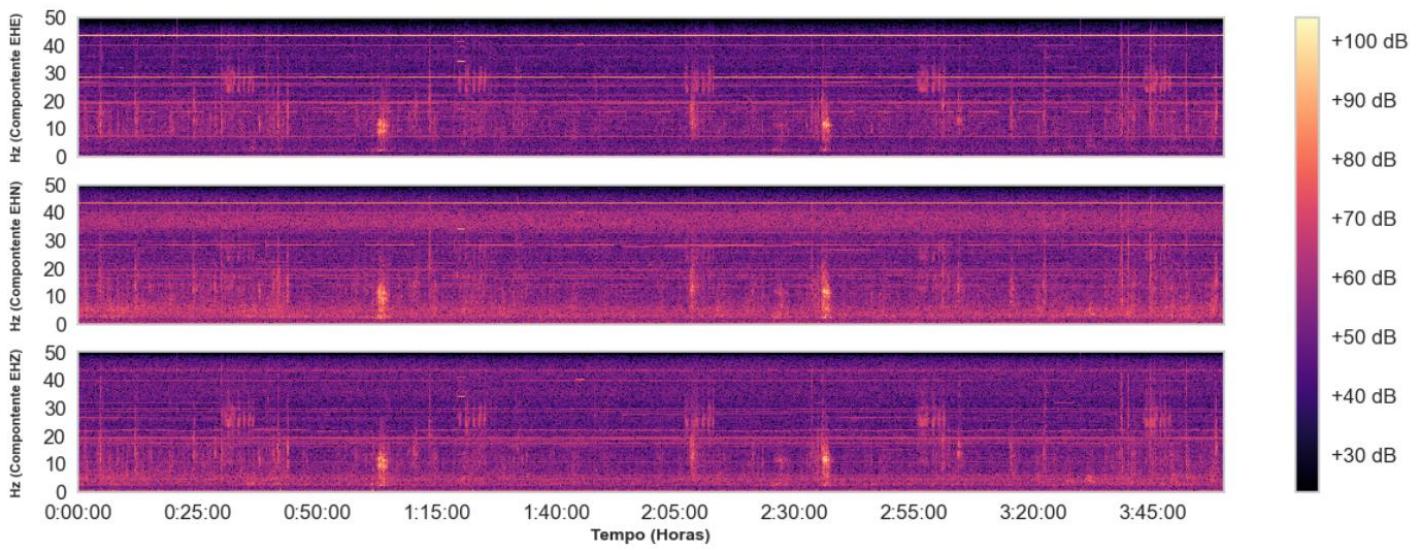


Figura 38 – Espectrograma para o Cenário 3 com os seguintes parâmetros: *frame size* (comprimento da janela de análise) = 1024 e *hop length* (deslocamento da janela de análise) = 512.

Tabela 5 – Média e desvio padrão dos atributos extraídos dos dados do Cenário 3.

Componente	EHE		EHN		EHZ	
Atributo	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão
EA	395,92	229,31	395,66	241,9	396,68	239,37
RMS	133,91	57,19	134,28	60,4	135,12	63,12
TCZ	0,72	0,08	0,72	0,09	0,72	0,09
REB	0,13	0,17	0,14	0,26	0,13	0,14
LBE	14,39	1,15	14,41	1,14	13,36	1,16
CE	22,84	1,97	22,85	1,97	22,89	1,95
PE	0,04	0,02	0,04	0,02	0,04	0,02
RE	42,18	2,86	42,21	2,79	42,19	2,79

#### 4.2.4. CENÁRIO 4

O processo de montagem está apresentado na Figura 39, onde pode ser observado o uso das estruturas auxiliares, e na Figura 40, onde está apresentada a configuração final do modelo em escala de laboratório construído para o Cenário 4. No Apêndice B está apresentada condição inicial do monitoramento deste cenário (Figura 4.B).



(a)



(b)



(c)



(d)



(e)

Figura 39 –Vista frontal das camadas durante o processo de compactação cenário 4.

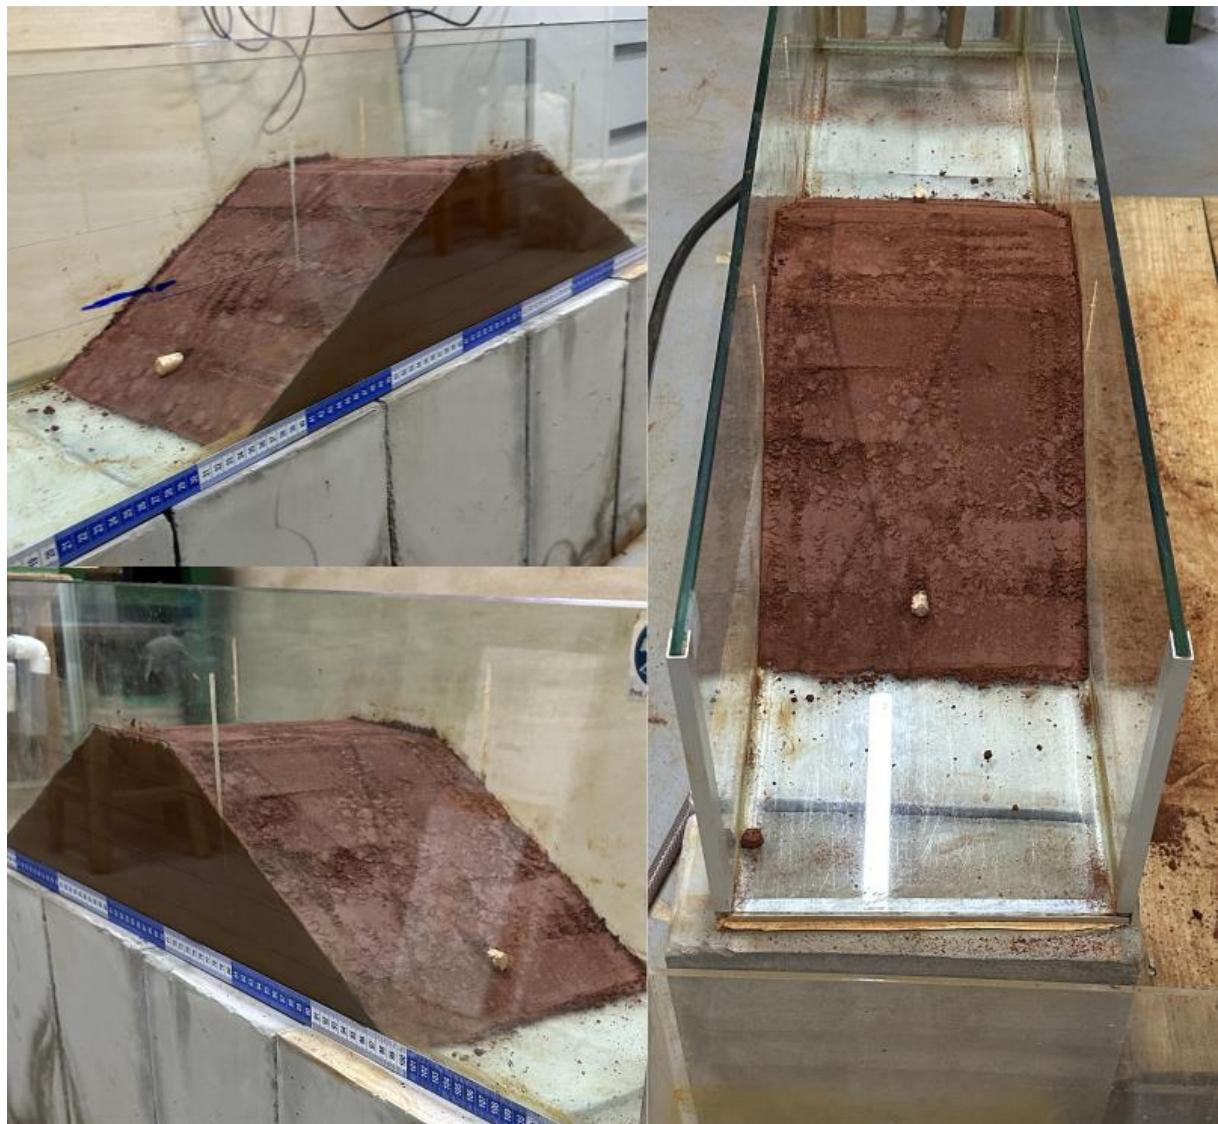


Figura 40 –Barragem montada cenário 4.

Os resultados das 4 horas de monitoramento do Cenário 4 estão apresentados na forma de sismograma (Figura 41) e espectrograma (Figura 42). Os atributos extraídos dos dados,

apresentados na Tabela 6, onde observa-se uma variação média da amplitude muito semelhante nas três componentes. No espectrograma observa-se que as três componentes apresentam conteúdos de frequência muito pronunciados. A componente EHZ apresenta conteúdo de frequência elevado na faixa de 0 a próximo de 50 Hz, um comportamento semelhante pode ser observado na componente EHN, com uma pequena diferença nas frequências de 20 a 30 Hz. Na componente EHE visualmente as frequências mais pronunciadas estão na faixa de 0 a 20 Hz. No Apêndice A, estão apresentadas as comparações dos valores de quatro atributos no tempo: o centroide espectral (Figura 1.Ad), a largura de banda espectral (Figura 2.Ad), a razão de energia de banda (Figura 3.Ad) e a taxa de cruzamento do zero (Figura 4.Ad).

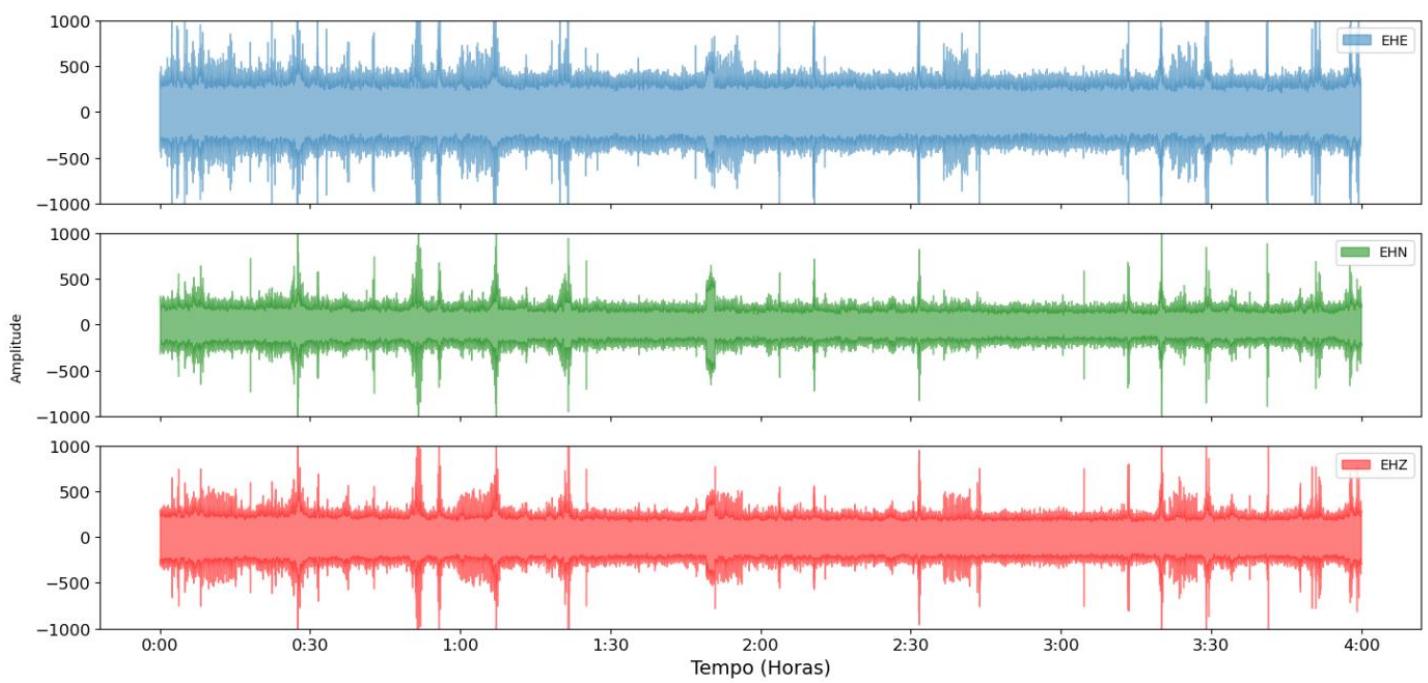


Figura 41 – Sismograma para o Cenário 4.

Em comparação com os resultados dos Cenários 1, 2 e 3, observa-se que houve uma diminuição no envelope de amplitude médio de todas as componentes. Isso indica que, em média, as componentes EHE, EHN e EHZ apresentaram uma variação menor de amplitude no Cenário 4, quando comparadas com os Cenários 1, 2 e 3. Essa observação não coincide com a relação que estava sendo observada até o Cenário 3, em que o efeito da diminuição do índice de vazios de cada cenário provocou um aumento no envelope de amplitude médio de todas as componentes. Em relação aos espectrogramas de frequência, os resultados obtidos no Cenário 4 diferem dos obtidos em todos os cenários apresentados anteriormente. Enquanto no Cenário 1 somente a componente EHN apresentou frequências mais pronunciadas durante todo o

período de monitoramento e nos Cenários 2 e 3 nenhuma das componentes apresentou um conteúdo de frequência muito elevado, no Cenário 4 todas as componentes apresentaram um conteúdo elevado de frequência.

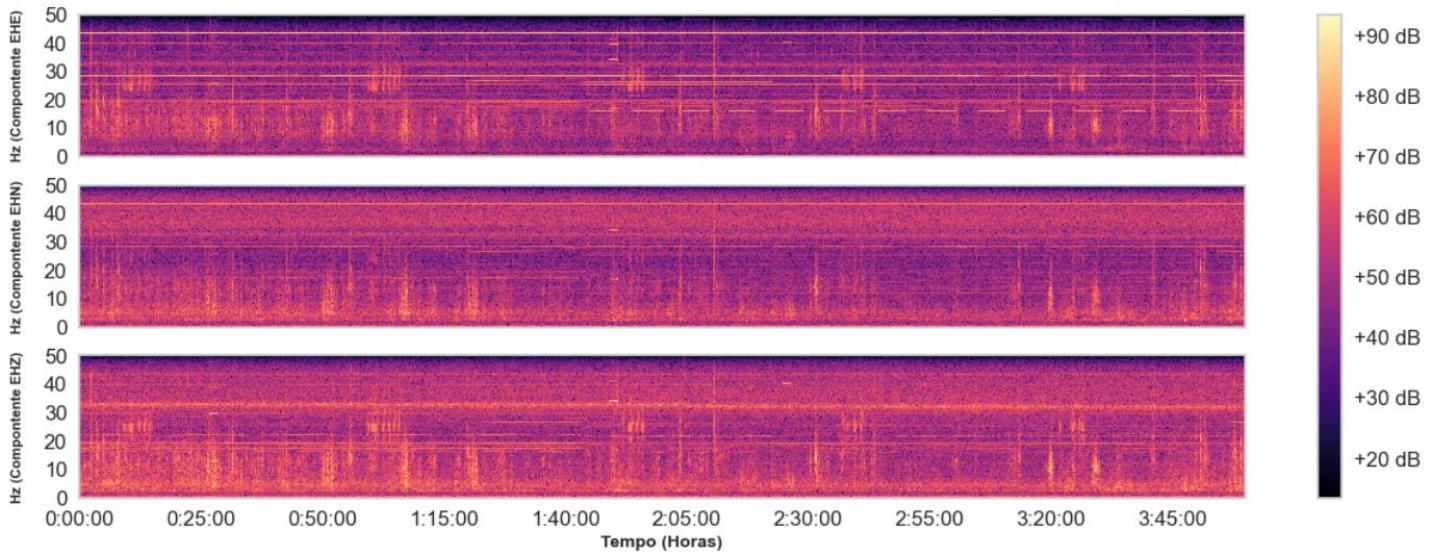


Figura 42 – Espectrograma para o Cenário 4 com os seguintes parâmetros: *frame size* (comprimento da janela de análise) = 1024 e *hop length* (deslocamento da janela de análise) = 512.

Tabela 6 – Média e desvio padrão dos atributos extraídos dos dados do Cenário 4.

Componente		EHE		EHN		EHZ	
Atributo	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão	
EA	368,97	204,9	366,69	172,39	366,17	179,98	
RMS	111,01	37,79	111,16	36,14	111,49	35,61	
TCZ	0,62	0,09	0,62	0,09	0,62	0,09	
REB	0,22	0,27	0,22	0,26	0,21	0,22	
LBE	13,63	1,22	13,98	1,21	13,93	1,22	
CE	22,92	1,94	22,96	1,91	22,96	1,86	
PE	0,08	0,06	0,08	0,06	0,08	0,05	
RE	41,21	2,94	41,27	2,81	41,11	2,91	

#### 4.2.5. CENÁRIO 5

O processo de montagem está apresentado na Figura 43, onde pode ser observado o uso das estruturas auxiliares, e na Figura 44, onde está apresentada a configuração final do modelo em escala de laboratório construído para o Cenário 5. No Apêndice B está apresentada condição inicial do monitoramento deste cenário (Figura 5.B).



(a)



(b)



(c)



(d)



(e)

Figura 43 –Vista frontal das camadas durante o processo de compactação cenário 5.

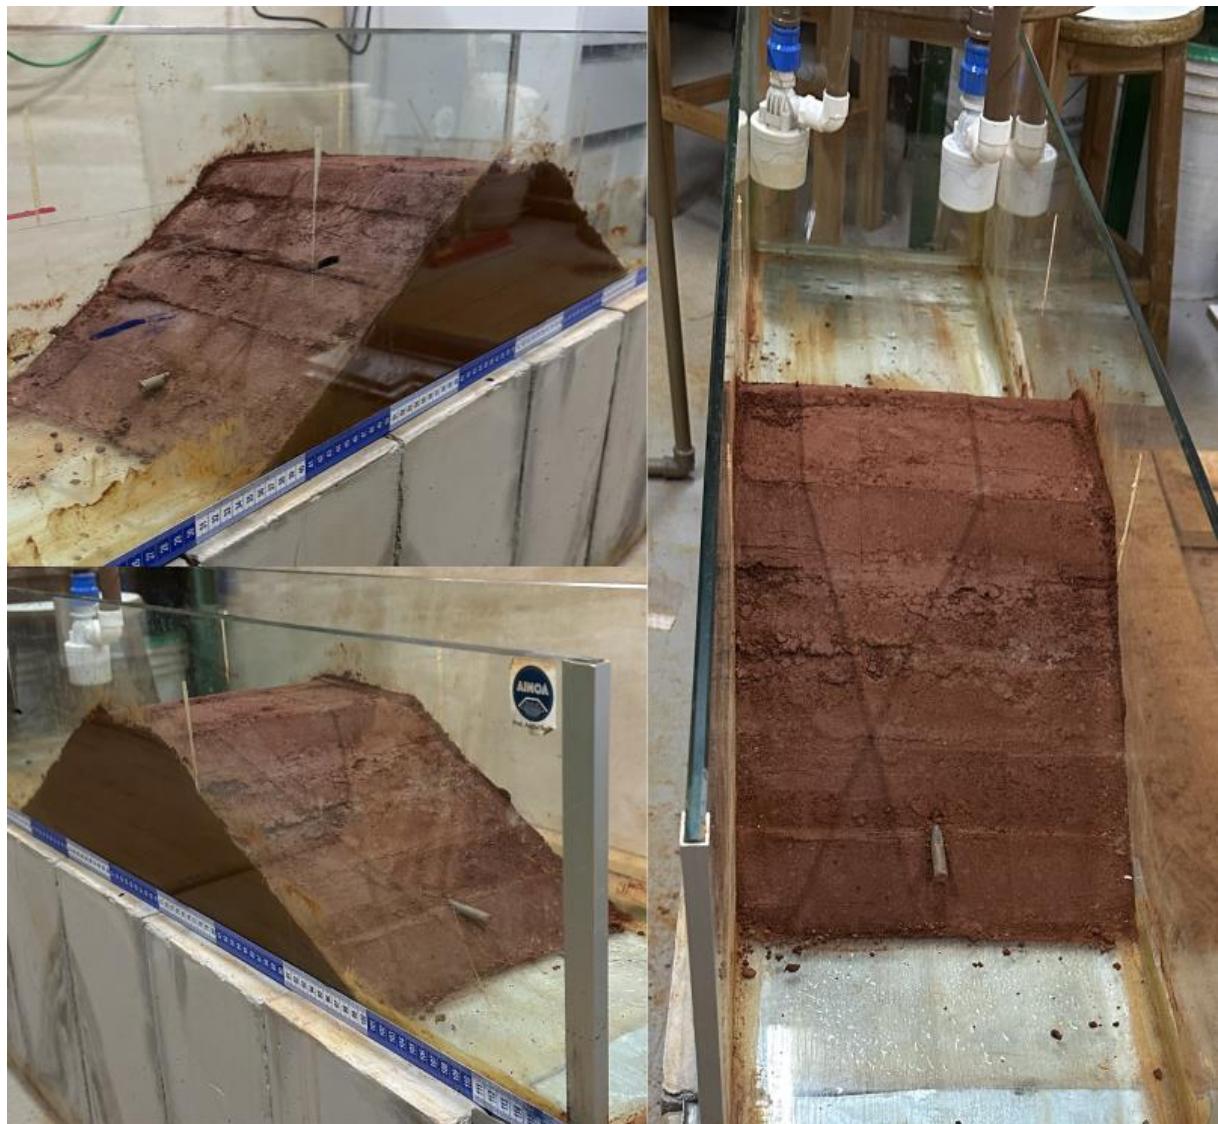


Figura 44 –Barragem montada do cenário 5 e do cenário dinâmico.

Os resultados das 4 horas de monitoramento do Cenário 5 estão apresentados na forma de sismograma (Figura 45) e espectrograma (Figura 46). Nos atributos extraídos dos dados,

apresentados na Tabela 7, observa-se uma variação média da amplitude muito semelhante nas três componentes. No espectrograma observa-se que a componente EHN apresentou um conteúdo de frequência mais pronunciado quando comparado com as componentes EHZ e EHE. No Apêndice A, estão apresentadas as comparações dos valores de quatro atributos no tempo: o centroide espectral (Figura 1.Ae), a largura de banda espectral (Figura 2.Ae), a razão de energia de banda (Figura 3.Ae) e a taxa de cruzamento do zero (Figura 4.Ae).

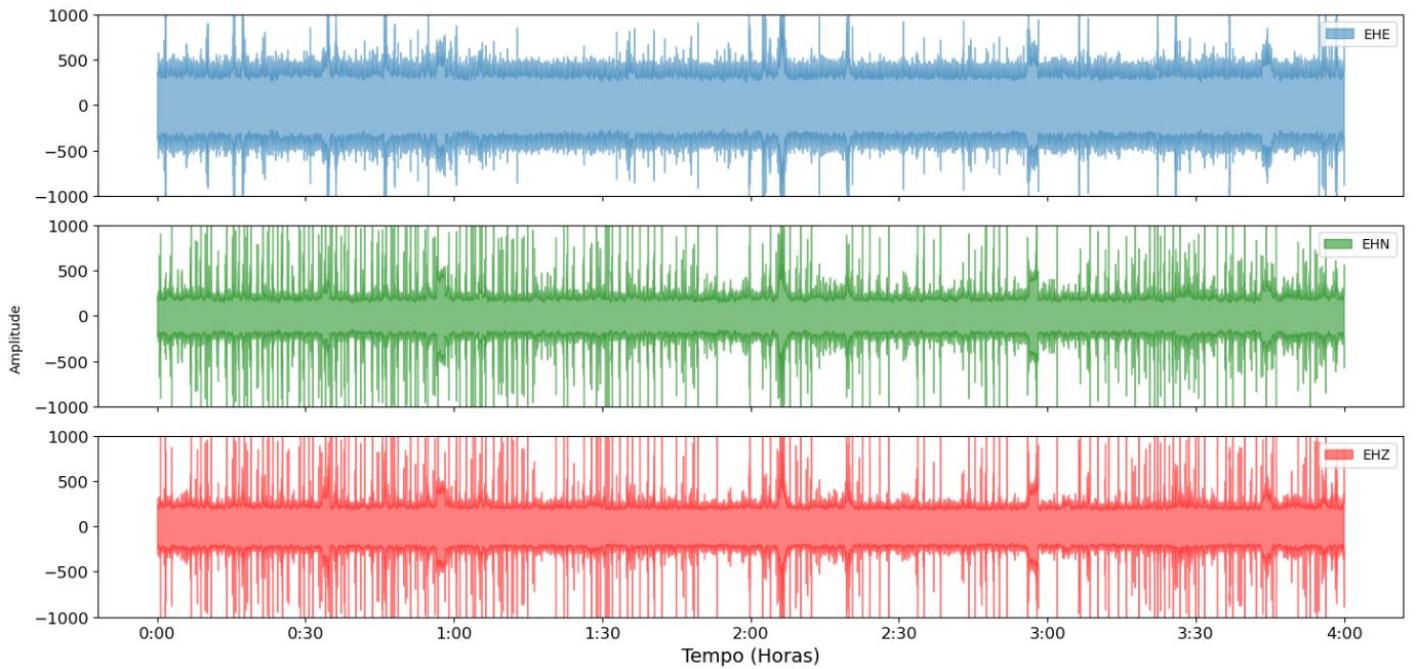


Figura 45 – Sismograma para o Cenário 5.

Em comparação com os resultados dos Cenários 1, 2, 3 e 4, observa-se que houve um aumento no envelope de amplitude médio de todas as componentes. Isso indica que, em média, as componentes EHE, EHN e EHZ apresentaram uma variação consideravelmente maior de amplitude no Cenário 5, quando comparadas com os Cenários 1, 2, 3 e 4. Além dessa constatação, é possível observar tanto nos sismogramas quanto nos espectrogramas, a ocorrência de uma série de picos durante o monitoramento, que aumentaram consideravelmente o desvio padrão do envelope de amplitude. Esses picos não foram observados em nenhum dos outros cenários de monitoramento, e em todos eles o tubo de acrílico estava presente no corpo do barramento. A retirada do tubo para permitir o carreamento do material no Cenário 5 pode ter sido o motivo da ocorrência de um sinal com um maior nível de ruídos. Em relação aos espectrogramas de frequência, os resultados obtidos no Cenário 5 diferem dos obtidos anteriormente principalmente em função dos picos de frequência observados em todas as

componentes, porém menos pronunciados na componente EHE. No pequeno intervalo entre os picos, é possível observar visualmente que as frequências estão mais pronunciadas na componente EHN, semelhante ao observado no Cenário 1.

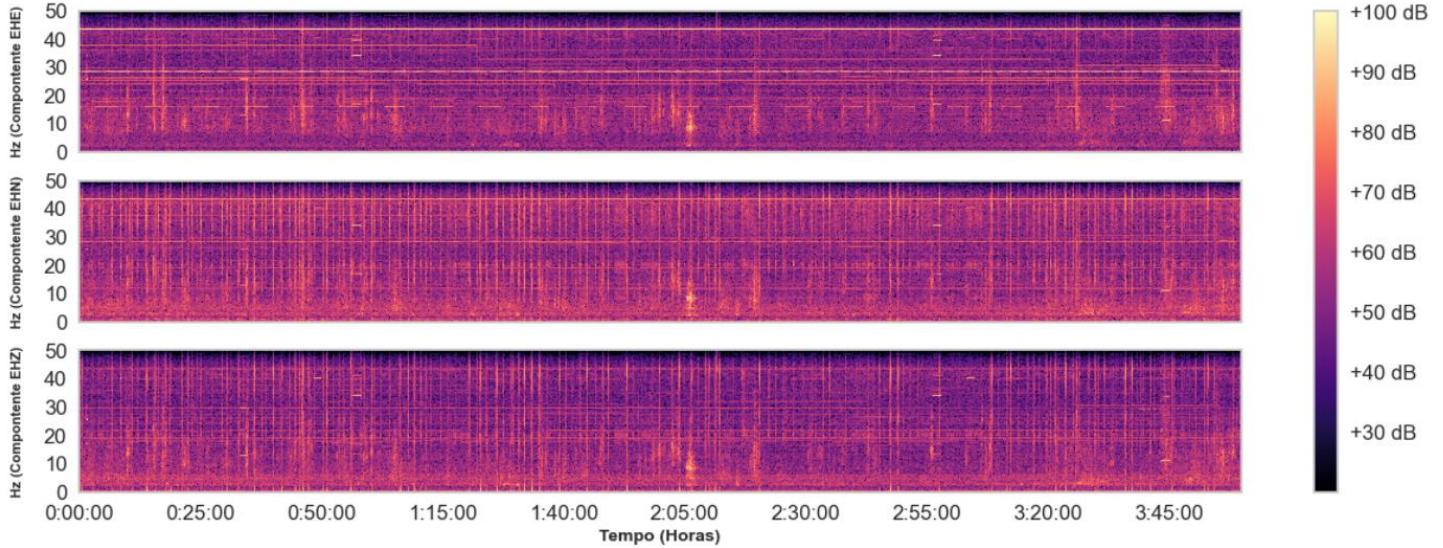


Figura 46 – Espectrograma para o Cenário 5 com os seguintes parâmetros: *frame size* (comprimento da janela de análise) = 1024 e *hop length* (deslocamento da janela de análise) = 512.

Tabela 7 – Média e desvio padrão dos atributos extraídos dos dados do Cenário 5.

Componente	EHE		EHN		EHZ	
Atributo	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão
EA	489,92	323,15	491,93	333,43	486,58	327,27
RMS	136,32	42,45	136,95	41,96	136,68	42,1
TCZ	0,7	0,08	0,69	0,08	0,7	0,08
REB	0,15	0,3	0,15	0,24	0,15	0,3
LBE	14,46	1,18	14,39	1,19	14,41	1,19
CE	23,55	2,37	23,56	2,34	23,57	2,31
PE	0,06	0,06	0,06	0,06	0,06	0,06
RE	42,82	1,81	42,74	1,87	42,8	1,86

### 4.3. ALGORITMO DE IDENTIFICAÇÃO DOS CENÁRIOS ESTÁTICOS

Nos dados de entrada para teste e treinamento dos algoritmos, a extração de atributos foi feita utilizando os seguintes parâmetros: *frame size* (comprimento da janela de análise) = 1024 e um *hop length* (deslocamento da janela de análise) = 512. Com os atributos extraídos, foram treinados os modelos de classificação e regressão, cujos resultados estão apresentados na Tabela 8.

Tabela 8 – Resumo da acurácia dos algoritmos de classificação e regressão avaliados para os dados de teste e treinamento.

Algoritmo	Validação cruzada		Acurácia	
	Média	Desvio padrão	Treino	Teste
<i>SGD Linear</i>	0,87	0,01	0,87	0,87
<i>Logistic Regression</i>	0,89	0,01	0,89	0,9
<i>k-Nearest Neighbors</i>	0,88	0,01	0,88	0,88
<i>Naive Bayes</i>	0,62	0,01	0,62	0,62
<i>Decision Tree</i>	0,82	0,02	0,82	0,78
<i>Random Forest</i>	0,97	0,01	0,97	0,96
<i>Support Vector Machine (SVM)</i>	0,98	0,00	0,98	0,98
<i>Multilayer Perceptron</i>	0,97	0,01	0,97	0,97
Algoritmos de regressão				
Algoritmo	MSE*	RMSE**	R <sup>2</sup> ***	
<i>Random Forest Regressor</i>	0,404	0,635	0,796	
<i>Support Vector Regressor</i>	0,353	0,594	0,822	

\*MSE – *Mean Squared Error* (Erro quadrático médio); \*\* RMSE – *Root Mean Squared Error* (Raiz do erro quadrático médio); \*\*\* R<sup>2</sup> - Coeficiente de determinação.

Dentre os modelos de classificação treinados, o *Naive Bayes* foi o que apresentou os piores resultados, seguido pelo algoritmo de árvores de decisão (*Decision Trees*). O *SGD Linear*, *k-Nearest Neighbors* e *Logistic Regression* apresentaram um desempenho semelhante, com acurácia no treino próxima a 0,90. Os modelos com os melhores desempenhos foram o *Support Vector Machine*, *Multilayer Perceptron* e *Random Forest*, com acurácia muito próxima de 1, significando que a diferenciação entre os cenários estáticas apresentou um melhor desempenho nesses três algoritmos. Entre os três melhores, foi escolhido o *Support Vector Machine*, uma vez que sua aplicação para análise de *piping* já foi registrada na literatura, nos trabalhos de Fisher *et al.* (2017) e Fisher *et al.* (2016).

Os resultados do treinamento utilizando o *10-fold cross validation* estão apresentados na Figura 47 e na Tabela 9, onde é possível observar que o algoritmo diferencia bem os cenários nos dados de teste. Além disso, os resultados da validação cruzada indicam um desvio padrão baixo entre os conjuntos de dados analisados, o que indica que o algoritmo não se tornou tendencioso na identificação dos dados de treinamento.

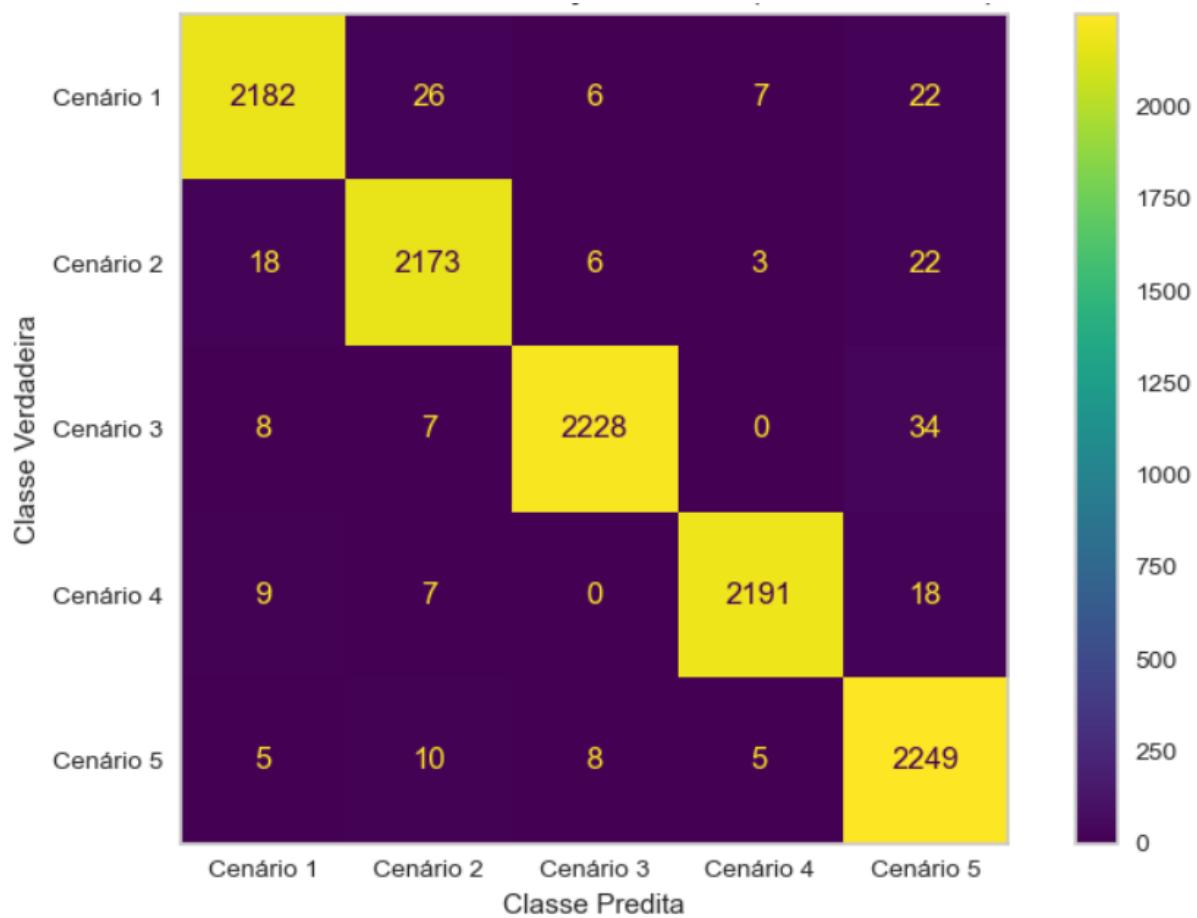


Figura 47 – Matriz de confusão com a validação cruzada para os dados de treino utilizando o modelo SVM.

Tabela 9 – Métricas de desempenho do algoritmo SVM nos dados de treinamento com validação cruzada.

Classe predita	Precisão	Recall	F1-Score
1	0,98	0,97	0,98
2	0,98	0,98	0,98
3	0,99	0,98	0,98
4	0,99	0,98	0,99
5	0,96	0,99	0,97
Acurácia		0,98	

Os resultados do algoritmo treinado nos dados de teste, apresentados na matriz de confusão da Figura 48 e nas métricas de desempenho da Tabela 10, destacam a capacidade do modelo de diferenciar os cenários de monitoramento estático, com valores próximos a 1 em todas as métricas de desempenho avaliadas.

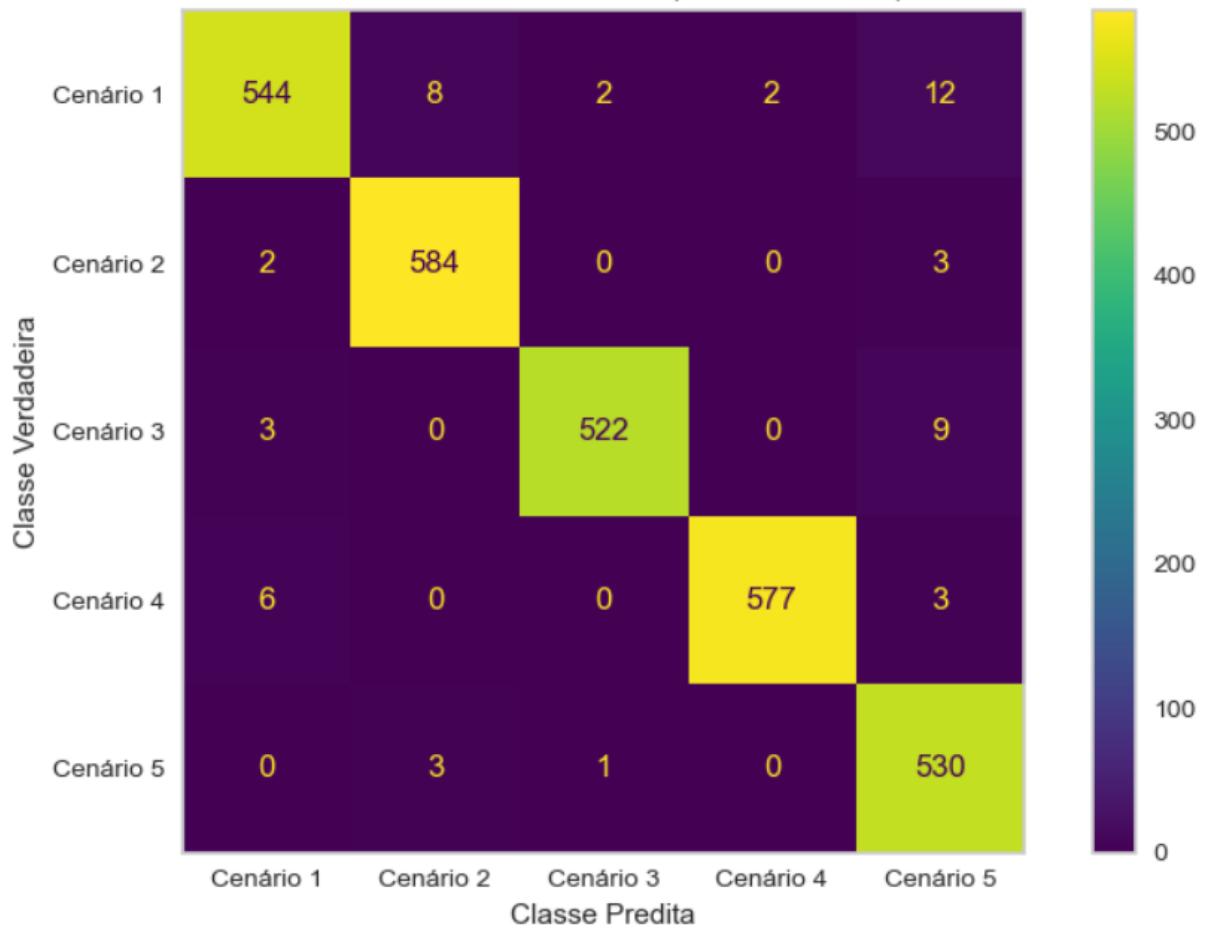


Figura 48 – Matriz de confusão para os dados de teste utilizando o modelo SVC.

Tabela 10 – Métricas de desempenho do algoritmo SVC nos dados de teste.

Classe predita	Precisão	Recall	F1-Score
1	0,98	0,96	0,97
2	0,98	0,99	0,99
3	0,99	0,98	0,99
4	1,00	0,98	0,99
5	0,95	0,99	0,97
<b>Acurácia</b>		0,98	

#### 4.4. MONITORAMENTO DO CENÁRIO DINÂMICO

O monitoramento do cenário dinâmico foi iniciado com a retirada da barra metálica, marcando o início do *piping*. Na Figura 49a é apresentada uma vista frontal do modelo de barragem no Cenário 5 após o final do processo de construção, enquanto a Figura 49b apresenta o momento após a retirada do tubo. Nos primeiros cinco dias após a retirada do tubo o monitoramento foi mantido mesmo sem a passagem de água, sendo o sistema de entrada de água ligado no início da noite e desligado na manhã do dia seguinte.

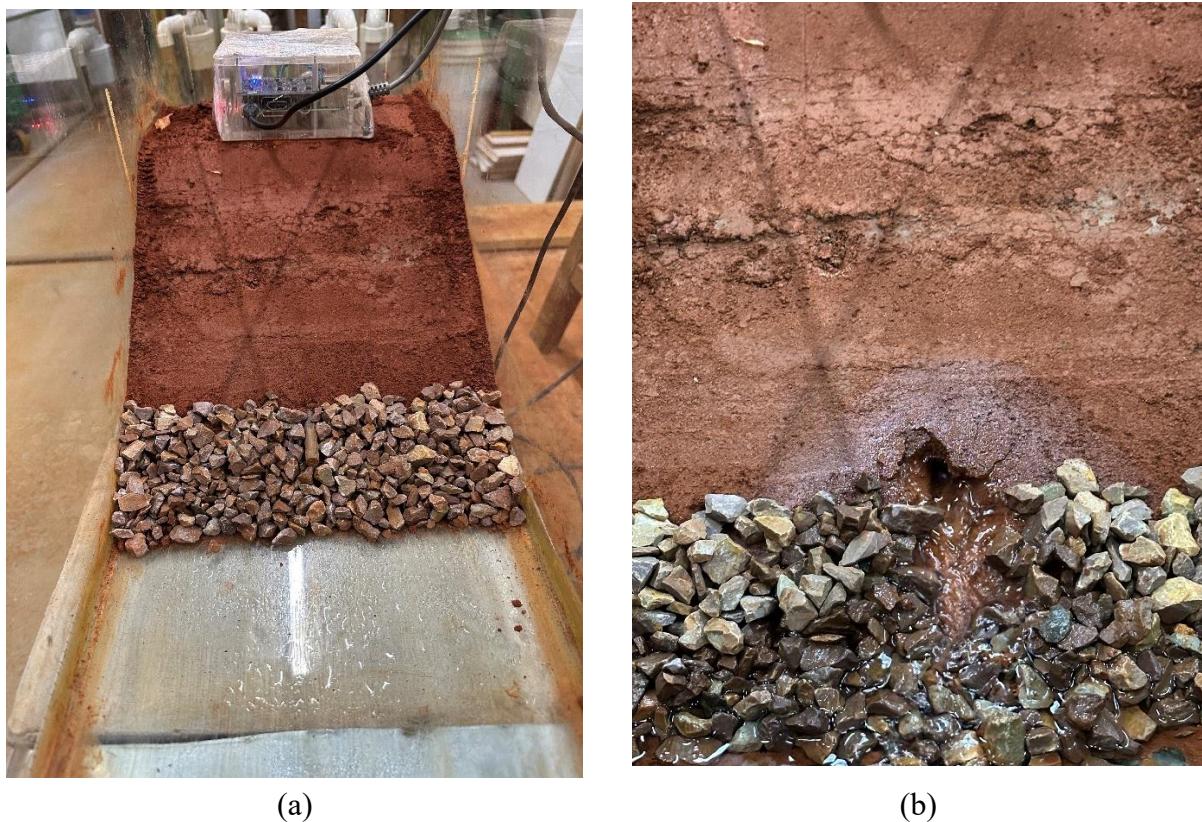
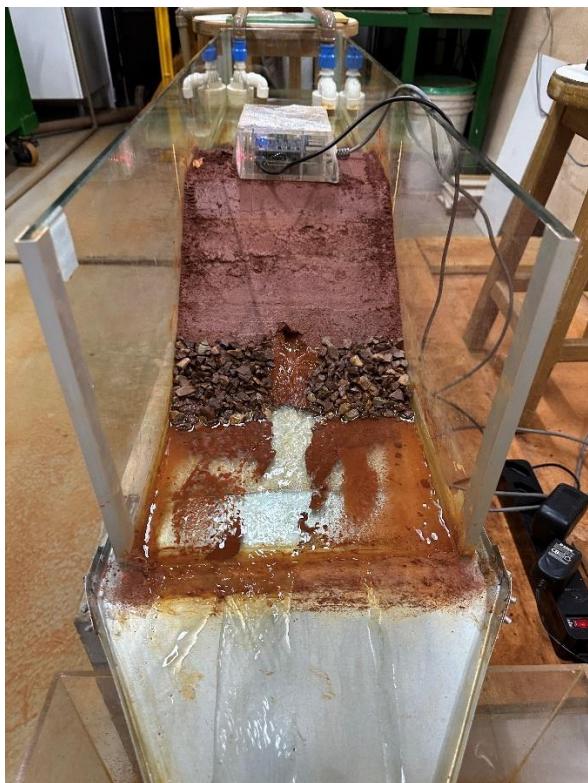


Figura 49 – Início do monitoramento: (a) antes da retirada do tubo metálico e; (b) após a retirada do tubo.

A Figura 50 apresenta o processo de evolução do *piping* nas duas semanas de monitoramento. A evolução da erosão na frente do barramento mostra que, até o oitavo dia (Figura 50f), houve pouco aumento do diâmetro do tubo, indicando que houve pouca alteração nas condições do meio até este ponto. Para acelerar o processo de erosão, no nono dia de monitoramento foi inserido um mergulhão no reservatório da barragem para aumentar a temperatura tanto da água como do solo. Alguns trabalhos na literatura, como os de Tran *et al.* (2020) e Akinola *et al.* (2019), indicam que o aumento da temperatura tanto da água como do solo influenciam na taxa de erosão de solos coesivos. Os resultados apresentados na Figura 50g em diante indicam que o aumento da temperatura da água contribuiu com o aumento da erosão, corroborando com os resultados obtidos pelos autores. O mergulhão foi mantido no reservatório de jusante durante 7 dias, quando a temperatura da água foi mantida em um intervalo de temperatura de 45 a 50° C. Nesse período, o sistema de entrada de água foi mantido ligado durante os dias e as noites de monitoramento.



(a)



(b)



(c)



(d)



(e)



(f)



(g)



(h)



(i)



(j)

Figura 50 – Evolução do *piping* durante duas semanas de monitoramento: (a) primeiro dia; (b) segundo dia; (c) terceiro dia; (d) quarto dia; (e) quinto dia; (f) oitavo dia; (g) décimo dia; (h) décimo primeiro dia; (i) décimo segundo dia; (j) décimo quinto dia.

#### 4.5. MEDIDA TRANSIENTE DO ÍNDICE DE VAZIOS

O resultado da previsão dos modelo de classificação selecionado para os dados das duas semanas de monitoramento está apresentado na Figura 51. Uma característica desse tipo de modelo é que a classificação é feita em valores discretos, nesse caso entre os cenários estáticos (1, 2, 3, 4 e 5), para cada valor de entrada no modelo. Para melhorar a tendência geral das previsões, está plotada a média móvel das previsões do modelo. Os resultados obtidos mostram que o modelo não apresentou um desempenho condizente com o observado em laboratório, com pequenas variações na descontinuidade induzida no barramento. Isso pode ser atribuído principalmente à falta de conhecimento sobre o comportamento sísmico esperado para o sensor entre os cenários estáticos de monitoramento.

Diante das observações dos resultados nos modelos de classificação, optou-se por adotar algoritmos de regressão. A vantagem da utilização desse tipo de algoritmo é que estes estabelecem uma relação entre as variáveis preditoras e a variável que se deseja prever, ou seja, o algoritmo prevê uma espécie de função que se ajusta aos dados. Com esta abordagem

esperava-se preencher a lacuna entre o comportamento sísmico conhecido, representado pelos cenários estáticos, e o comportamento sísmico esperado no intervalo entre os índices de vazios conhecidos. Os resultados apresentados na Figura 52 mostram que o modelo de regressão com o melhor coeficiente de determinação também não foi capaz de reproduzir o comportamento monitorado em laboratório.

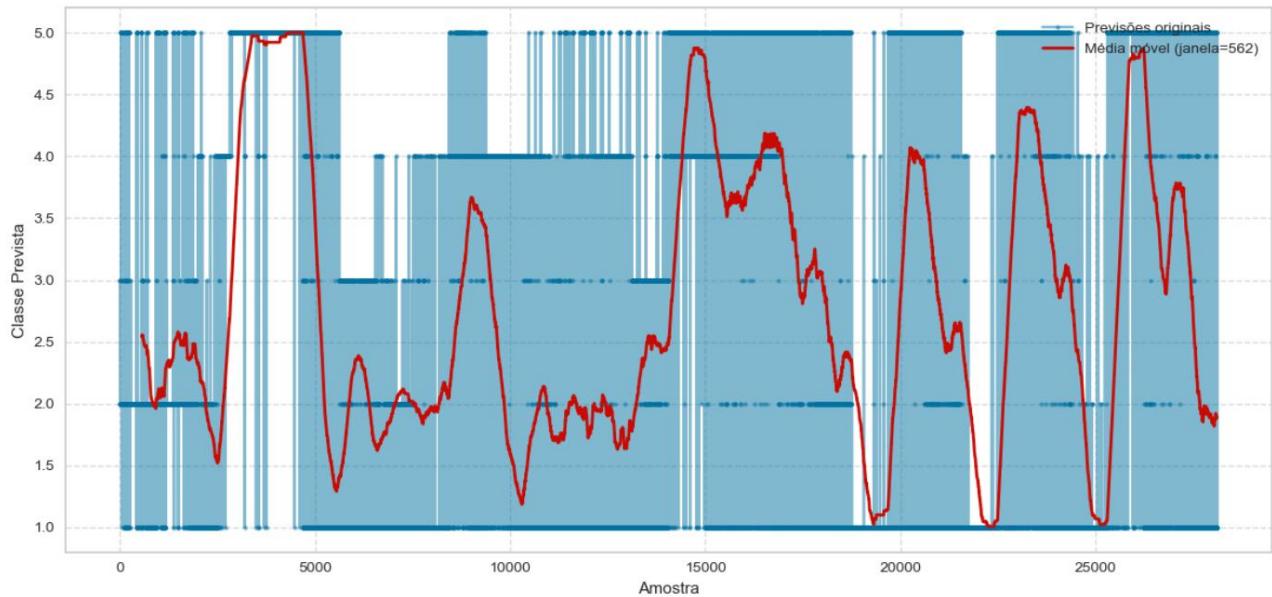


Figura 51 – Previsões do modelo SVM durante o monitoramento dinâmico e média móvel dos valores previstos.

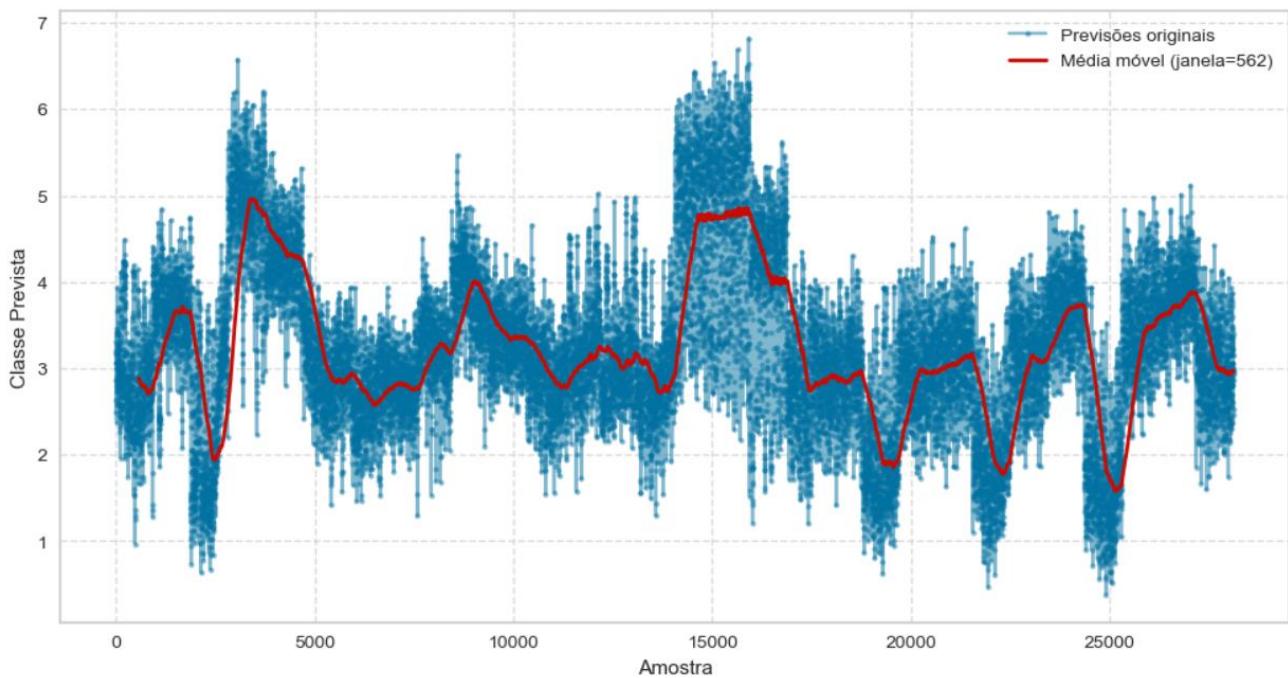


Figura 52 – Previsões do modelo de regressão *Support Vector Regressor* durante o monitoramento do cenário dinâmico e média móvel dos valores previstos.

A Tabela 11 apresenta o cálculo do diâmetro que o tubo deveria atingir no interior do barramento para provocar uma variação do índice de vazios equivalente do meio até atingir o índice de vazios calculado nos Cenários 2 e 3 (0,74 e 0,86, respectivamente). A partir dos resultados apresentados, é interessante observar que para atingir o índice de vazios calculado para o Cenário 2, seria necessário que o diâmetro do tubo aumentasse para 4,0cm, o que corresponderia a uma massa de solo perdida de 1,134kg. No caso do Cenário 3, o aumento deveria ser ainda maior, com o tubo chegando a 6,0cm de diâmetro, com 2,484kg de material carreado. Conforme observado na Figura 50j, após o décimo quinto dia de monitoramento não houve um aumento tão grande do cilindro, indicando tanto pelo aspecto visual da barragem quanto pelo volume de água que passava pelo barramento.

Tabela 11 – Cálculo da variação do índice de vazios para a alteração no diâmetro do tubo simulando o desenvolvimento de *piping* no barramento.

Diâmetro cilindro (cm)	Massa de solo perdida (kg)	Massa da barragem - Cenário 5 (kg)	Massa restante (kg)	$\gamma_{d,final}$ (kN/m <sup>3</sup> )	e
0,8	0,043	22,07	22,026	16,06	0,65
1,2	0,097	22,07	21,972	16,02	0,65
1,6	0,175	22,07	21,894	15,96	0,66
2,0	0,277	22,07	21,792	15,88	0,67
2,4	0,403	22,07	21,665	15,79	0,68
2,8	0,556	22,07	21,513	15,68	0,69
3,2	0,735	22,07	21,334	15,55	0,70
3,6	0,926	22,07	21,143	15,41	0,72
4,0	1,134	22,07	20,935	15,26	0,74
4,4	1,372	22,07	20,696	15,09	0,76
4,8	1,637	22,07	20,432	14,89	0,78
5,2	1,915	22,07	20,154	14,69	0,80
5,6	2,193	22,07	19,876	14,49	0,83
6,0	2,484	22,07	19,585	14,28	0,86

A comparação dos resultados obtidos com o comportamento esperado, com base no observado em laboratório, mostram que no monitoramento de cenário dinâmico os algoritmos de classificação e regressão não foram capazes de identificar a variação do índice de vazios no tempo. Como a não correlação entre os comportamentos foi observada na transição dos cenários estáticos para o cenário dinâmico, em que a principal diferença está relacionada à ausência do tubo de acrílico e ao carreamento de material, ambos os efeitos combinados podem ter sido determinantes para não permitir correlacionar os dois monitoramentos. A escolha do

comprimento e do deslocamento da janela de análise também pode estar relacionada aos problemas observados, uma vez que se trata de um *tradeoff* entre o nível de detalhe observado no sinal e a inclusão de eventos que podem não ser representativos do sinal como um todo. Como foram utilizados vários atributos no domínio do tempo e da frequência, a janela de análise utilizada pode ter capturado eventos que ocorreram especificamente na noite de monitoramento de cada cenário estático, permitindo a diferenciação entre eles, porém inviabilizando a identificação da variação do índice de vazios no cenário dinâmico.

Na montagem dos ensaios, a condição de contorno da presença do tubo acrílico pode ter sido um fator limitante. Para contornar esse problema, ensaios que permitam simular e monitorar a evolução do *piping* sem a necessidade do tubo acrílico, poderiam permitir conhecer melhor o comportamento sísmico/acústico do material. A utilização de sensores que permitam obter as velocidades das ondas P e S também podem ser interessantes para relacionar a alteração no comportamento elástico do material com a evolução do *piping*.

## 5. CONCLUSÕES E SUGESTÕES PARA PESQUISAS FUTURAS

Com o estudo realizado do monitoramento sísmico passivo da variação do índice de vazios em modelos de barragem em escala de laboratório, são elencadas as seguintes conclusões:

- A escolha do índice de vazios como parâmetro intermediário que se relaciona com a ocorrência de *piping* mostrou-se interessante, uma vez que a análise visual dos resultados da etapa 1 mostram que os sensores utilizados são capazes de detectar diferenças que incluem a variação do índice de vazios do meio;
- A simulação dos cenários com índice de vazios constante e com a presença de uma descontinuidade no modelo de barragem, utilizada para simular a ocorrência de *piping*, aliado aos algoritmos de inteligência artificial de classificação e regressão, permitiram observar que, nas condições ensaiadas, é possível estabelecer uma relação entre diferentes valores do índice de vazios e o comportamento sísmico do material;
- A simulação do cenário dinâmico, com variação do índice de vazios no tempo, partindo do cenário de 100% da energia do *Proctor* Normal na umidade ótima mostrou que, nas dimensões propostas para o modelo em laboratório, a carga hidráulica do reservatório da barragem não foi suficiente para causar o desprendimento e arraste das partículas sob condições normais. Neste caso, o aumento da temperatura ajudou no aumento da taxa de erosão, porém, durante o tempo monitorado, visualmente não foram observadas mudanças expressivas no diâmetro do *piping* induzido no início do ensaio;
- A utilização do algoritmo calibrado para os cenários estáticos não foi eficiente na previsão da variação do índice de vazios do cenário dinâmico. Os resultados obtidos não foram condizentes tanto com o comportamento do material sob as condições simuladas, onde esperava-se ver uma variação gradual do índice de vazios com o tempo de monitoramento, quanto com as observações visuais da evolução do *piping* em laboratório, que demonstraram uma evolução lenta do diâmetro do tubo, particularmente nos primeiros 5 dias de monitoramento;
- A não correlação obtida entre os comportamentos monitorados nos cenários estáticos e o comportamento monitorado no cenário dinâmico pode ser justificada pela falta de conhecimento da assinatura sísmica do material para um conjunto maior de índices de vazios. A alteração na assinatura sísmica do material com e sem o tubo, que representa a principal diferença entre os cenários estáticos e dinâmico, também pode estar relacionada com os resultados obtidos nos ajustes dos algoritmos.

Para aperfeiçoar a metodologia proposta e permitir evoluir no estudo para possibilitar sua aplicação em barragens reais, identificando o seu estado e possibilitando o fornecimento de informações para tomadas de decisões, são propostas as seguintes recomendações para trabalhos futuros na área:

- Caracterização do comportamento sísmico/acústico dos materiais em condições mais controladas, utilizando um ensaio *pinhole* adaptado para permitir monitorar a amostra durante o ensaio. Desta forma seria possível monitorar as variações no sinal monitorado somente em função do carreamento do material, evitando a interferência de outras condições externas.
- Adaptação do ensaio de simulação do desenvolvimento de *piping* no tempo (cenário dinâmico) para permitir o monitoramento da quantidade de material carreado, permitindo obter uma medida direta da variação do índice de vazios equivalente por meio da perda de massa da barragem. Isso permitiria obter um parâmetro para verificar de forma qualitativa o índice de vazios da barragem no tempo monitorado, comparando esses resultados com as previsões dos algoritmos de IA.
- Utilização de um modelo de *Machine Learning* que possua uma dependência temporal (como o *Long Short-Term Memory* – LSTM), uma vez que o *piping* é um fenômeno que depende do tempo de ensaio para desenvolver. Esse tipo de algoritmo talvez tenha a capacidade de identificar essa dependência temporal, permitindo prever a assinatura sísmica do material diante das variações entre os cenários conhecidos, auxiliando na previsão do estado da barragem no cenário dinâmico.
- Utilização de sensores que permitam conhecer a variação das velocidades das ondas P e S, permitindo estabelecer relações com o comportamento elástico do material. A variação monitorada no comportamento dos materiais poderia ser utilizada para conhecer mudanças relacionadas ao desenvolvimento do *piping*, permitindo relacionar diretamente o comportamento mecânico na fase elástica com a ruptura por este tipo de mecanismo.
- A validação do modelo é outra questão pertinente e importante, portanto a elaboração de um estudo de caso para aplicação da metodologia proposta inicialmente para laboratório seria um passo importante para permitir a aplicação em casos reais.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Adamo, N., Al-Ansari, N., Sissakian, V., Laue, J., & Knutsson, S. (2020). Geophysical Methods and their Applications in Dam Safety Monitoring. *Journal of Earth Sciences and Geotechnical Engineering*, 11(1), 291–345. doi: 10.47260/jesge/1118
- Akinola, A. I., Wynn-Thompson, T., Olgun, C. G., Mostaghimi, S., & Eick, M. J. (2019). Fluvial Erosion Rate of Cohesive Streambanks Is Directly Related to the Difference in Soil and Water Temperatures. *Journal of Environmental Quality*, 48(6), 1741–1748. doi: 10.2134/jeq2018.10.0385
- Albuquerque, E. A. C., Diniz, M. dos S., Borges, L. P. d. F., & Ozelim, L. C. de S. M. (2022). *Relatório de Produto: Modelo de Machine Learning Supervisionado Desenvolvido com os Dados Experimentais e Aplicado na Barragem do Paranoá-DF*. Brasília, DF, Brasil.
- Relatório de Segurança de Barragens*. Brasília, DF, Brasil.
- Baladram, S. (2024). *Multilayer Perceptron, Explained: A Visual Guide with Mini 2D Dataset*. Retrieved from <https://towardsdatascience.com/multilayer-perceptron-explained-a-visual-guide-with-mini-2d-dataset-0ae8100c5d1c/>
- Bhavsar, H., & Panchal, M. H. (2012). A Review on Support Vector Machine for Data Classification. *International Journal of Advanced Research in Computer Engineering & Technology*, 1(10), 2278–1323.
- Biau, G., & Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197–227. doi: 10.1007/s11749-016-0481-7
- Bonelli, S. (2013). Erosion in Geomechanics Applied to Dams and Levees. In Erosion in Geomechanics Applied to Dams and Levees. doi: 10.1002/9781118577165
- Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A Survey. In ACM Computing Surveys. doi: 10.1145/1541880.1541882

Collantes, R. D. C. P. (2022). *Influência da temperatura na sucção e comportamento mecânico dos solos tropicais compactados*. Tese de Doutorado, G.TD - 174/2022, Universidade de Brasília, Brasília, Brasil.

Cruz, P. T. da. (1996). *100 barragens brasileiras: casos históricos, materiais de construção, projeto* (2<sup>a</sup>, 4<sup>a</sup> rei). São Paulo: Oficina de Textos.

Fell, R., & Fry, J. J. (2007). The state of the art of assessing the likelihood of internal erosion of embankment dams, water retaining structures and their foundations. In Internal Erosion of Dams and Their Foundations. CRC Press. doi: 10.1201/9781482266146-6

Fisher, W. D., Camp, T. K., & Krzhizhanovskaya, V. V. (2016). Crack detection in earth dam and levee passive seismic data using support vector machines. *Procedia Computer Science*, 80, 577–586. doi: 10.1016/j.procs.2016.05.339

Fisher, W. D., Camp, T. K., & Krzhizhanovskaya, V. V. (2017). Anomaly detection in earth dam and levee passive seismic data using support vector machines and automatic feature selection. *Journal of Computational Science*, 20, 143–153. doi: 10.1016/j.jocs.2016.11.016

Foster, M., Fell, R., & Spannagle, M. (2000). The statistics of embankment dam failures and accidents. *Canadian Geotechnical Journal*, 37(5), 1000–1024. doi: 10.1139/t00-030

Géron, A. (2019). *Hands-on Machine Learning with Scikit-Learn , Keras & TensorFlow* (2nd Ed.). Sebastopol, CA: O'Reilly Media, Inc.

Giannopoulos, T., & Pikrakis, A. (2014). *Introduction to audio analysis, a MATLAB Approach*. Academic Press.

Hanson, G., Tejral, R. D., Hunt, S. L., & Temple, D. M. (2010). Internal Erosion and Impact of Erosion Resistance. *USSDams 2010*.

Hardy Jr., H. R. (2003). *Acoustic Emission/Microseismic Activity* (1st ed., Vols. 1-Princi). The Pennsylvania State University, University Park, Pennsylvania, EUA: A.A.Balkema

Publishers.

Hickey, C. J., Ekimov, A., Hanson, G. J., & Sabatier, J. M. (2009). Time-lapse seismic measurements on a small earthen embankment during an internal erosion experiment. *Proceedings of the Symposium on the Application of Geophysics to Engineering and Environmental Problems, SAGEEP, 1*(May 2015), 163–175. doi: 10.4133/1.3176689

IBM. (2025a). *What are Naive Bayes Classifiers?* Retrieved from <https://www.ibm.com/think/topics/naive-bayes>

IBM. (2025b). *What is a decision tree?* Retrieved from <https://www.ibm.com/think/topics/decision-trees>

IBM. (2025c). *What is random forest?* Retrieved from <https://www.ibm.com/think/topics/random-forest>

IBM. (2025d). *What is the k-nearest neighbors (kNN) algorithm?* Retrieved from <https://www.ibm.com/think/topics/knn>

ICOLD. (2020). *World Register of Dams: General Synthesis.* Retrieved from [https://www.icold-cigb.org/GB/world\\_register/general\\_synthesis.asp](https://www.icold-cigb.org/GB/world_register/general_synthesis.asp)

Lee, F. (2025a). *Classification vs regression.* IBM. Retrieved from <https://www.ibm.com/think/topics/classification-vs-regression>

Lee, F. (2025b). *What is logistic regression?* IBM. Retrieved from <https://www.ibm.com/think/topics/logistic-regression>

Lopes, M. M. (2019). *Estudo do comportamento físico-mecânico de solos reforçados com fibras de açaí.* Projeto Final em Engenharia Ambiental, Universidade de Brasília, Brasília, DF.

Lu, Z., & Wilson, G. V. (2012). Acoustic Measurements of Soil Pipeflow and Internal Erosion. *Soil Science Society of America Journal, 76*(3), 853–866. doi: 10.2136/sssaj2011.0308

Minakov, A., & Yarushina, V. (2021). Elastoplastic source model for microseismicity and acoustic emission. *Geophysical Journal International*, 227(1), 33–53. doi: 10.1093/gji/ggab207

Mitrovic, D., Zeppelzauer, M., & Breiteneder, C. (2010). Features for content-based audio retrieval. *Advances in Computers*, 78, 71–150. doi: [https://doi.org/10.1016/S0065-2458\(10\)78003-7](https://doi.org/10.1016/S0065-2458(10)78003-7)

Neves, J. P. (2025). *Análise de Suscetibilidade de deslizamentos superficiais de talude de solo tropical não saturado sob situação de precipitações intensas utilizando equipamento de simulação em tempo real*. Universidade de Brasília. Doutorado em Engenharia Civil - Geotecnia. Trabalho em andamento.

Ozelim, L. C. de S. M., Borges, L. P. d. F., Cavalcante, A. L. B., Albuquerque, E. A. C., Diniz, M. dos S., Góis, M. S., Costa, K. R. C. B., Souza, P. F., Dantas, A. P. do N., Jorge, R. M., Moreira, G. R., Barros, M. L., & Aquino, F. R. (2022). Structural health monitoring of dams based on acoustic monitoring, deep neural networks, fuzzy logic and a CUSUM control algorithm. *Sensors*, 22(2482), 1–25. doi: <https://doi.org/10.3390/s22072482>

Parekh, M. L. (2016). *Advanced Internal Erosion Monitoring Using Seismic Methods in Field and Laboratory Studies*. Colorado School of Mines.

Pirogova, A. S., Tikhotskii, S. A., Tokarev, M. Y., & Suchkova, A. V. (2019). Estimation of Elastic Stress-Related Properties of Bottom Sediments via the Inversion of Very- and Ultra-High-Resolution Seismic Data. *Izvestiya - Atmospheric and Ocean Physics*, 55(11), 1755–1765. doi: 10.1134/S0001433819110124

Planès, T., Mooney, M. A., Rittgers, J. B. R., Parekh, M. L., Behm, M., & Snieder, R. (2016). Time-lapse monitoring of internal erosion in earthen dams and levees using ambient seismic noise. *Geotechnique*, 66(4), 301–312. doi: 10.1680/jgeot.14.P.268

Rahimi, S., Moody, T., Wood, C., Kouchaki, B. M., Barry, M., Tran, K., & King, C. (2019). Mapping Subsurface Conditions and Detecting Seepage Channels for an Embankment

Dam Using Geophysical Methods: A Case Study of the Kinion Lake Dam. *Journal of Environmental and Engineering Geophysics*, 24(3), 373–386. doi: 10.2113/JEEG24.3.373

Rebolledo, J. F. R., León, R. F. P., & Camapum de Carvalho, J. (2019). Obtaining the Mechanical Parameters for the Hardening Soil Model of Tropical Soils in the City of Brasília. *Soils and Rocks*, 42(1), 61–74. doi: 10.28927/sr.421061

Rittgers, J. B., Revil, A., Planes, T., Mooney, M. A., & Koelewijn, A. R. (2015). 4-D imaging of seepage in earthen embankments with time-lapse inversion of self-potential data constrained by acoustic emissions localization. *Geophysical Journal International*, 200(2), 758–772. doi: 10.1093/gji/ggu432

Robbins, B. A., & Griffiths, D. V. (2018). Internal erosion of embankments: A review and appraisal. *Geotechnical Practice Publication, 2018-Novem*(GPP 12), 61–75. doi: 10.1061/9780784481936.005

Scikit-learn. (2025). *Stochastic Gradient Descent*. Retrieved from <https://scikit-learn.org/stable/modules/sgd.html>

Sidharth, G. (2025). *Support Vector Regression: A Comprehensive Guide with Examples*. Retrieved from <https://www.quarkml.com/2022/11/support-vector-regression-a-complete-guide-with-example.html>

Silva, A. B., Velho, P., & Velho, P. (2024). *POTENCIAL USO GEOTÉCNICO DE FIBRAS DE AÇAÍ COMO REFORÇO DE SOLOS ARGILOSOS: ESTUDO GEOTÉCNICO EXPERIMENTAL COMPARATIVO DE RESISTÊNCIA AO CISALHAMENTO*. 1–8.

Singh, A. (2017). Anomaly Detection for Temporal Data using Long Short-Term Memory (LSTM). *Trita-Ict-Ex Nv - 2017:124, Independen*, 52. Retrieved from <http://kth.diva-portal.org/smash/record.jsf?pid=diva2:1149130>

Strahser, M., Jouniaux, L., Sailhac, P., Matthey, P. D., & Zillmer, M. (2011). Dependence of seismoelectric amplitudes on water content. *Geophysical Journal International*, 187(3), 1378–1392. doi: 10.1111/j.1365-246X.2011.05232.x

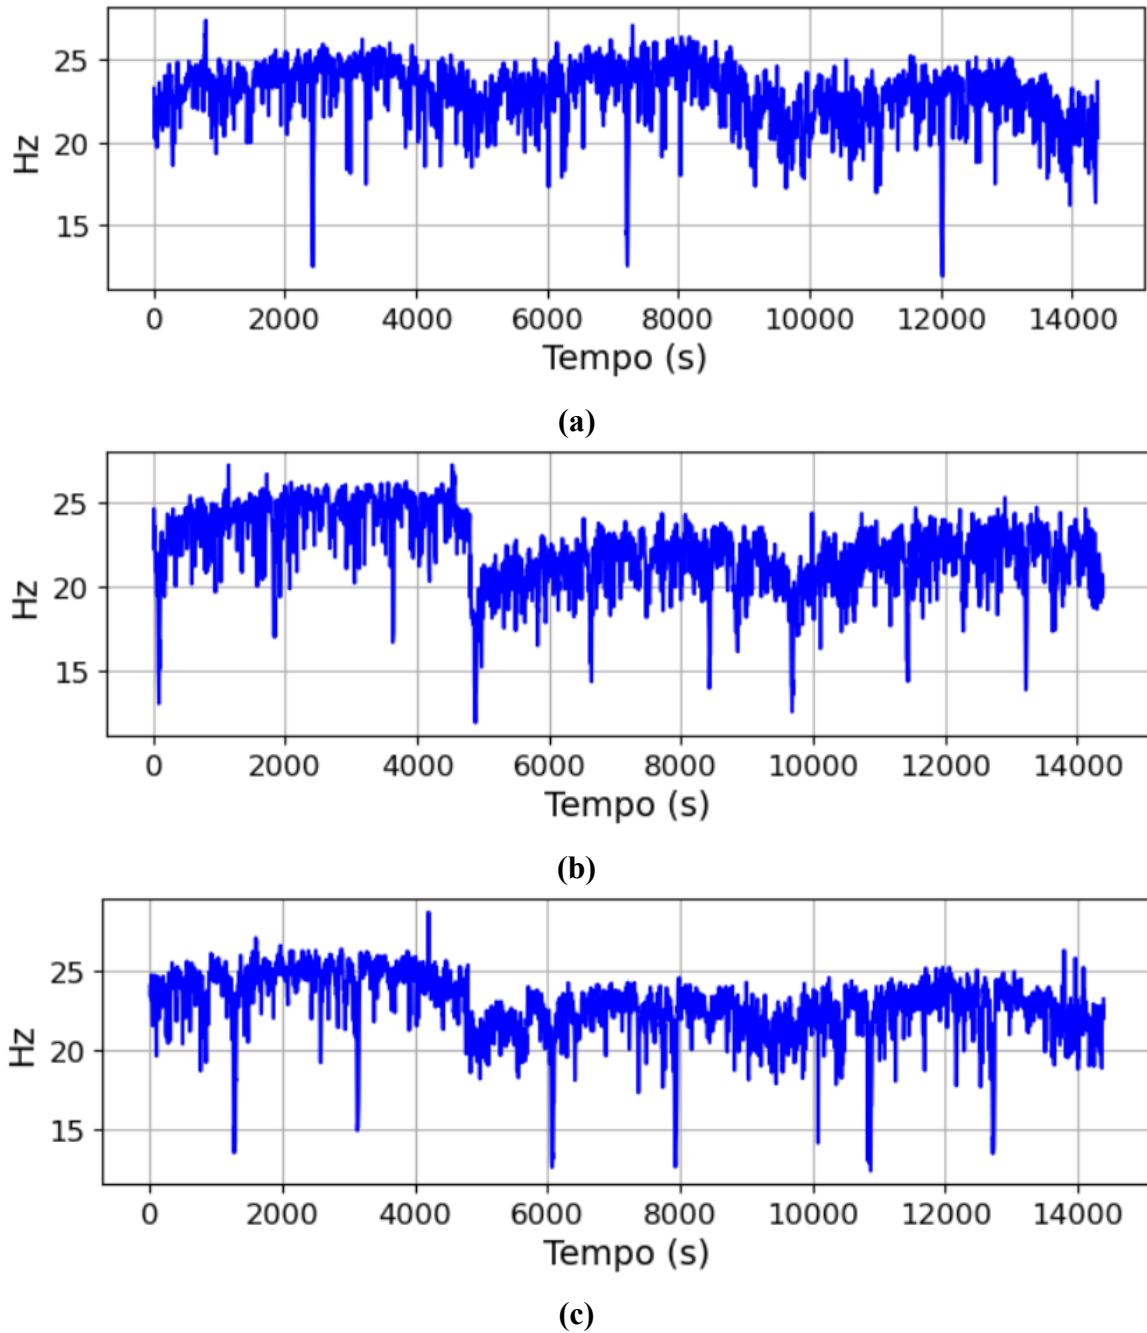
Tran, T. V., Karim, M. Z., Kuili, S., Tucker-Kulesza, S. E., & Derby, M. M. (2020). Temperature Effects on Cohesive Geomaterial Erodibility. *Journal of Materials in Civil Engineering*, 32(2). doi: 10.1061/(asce)mt.1943-5533.0003046

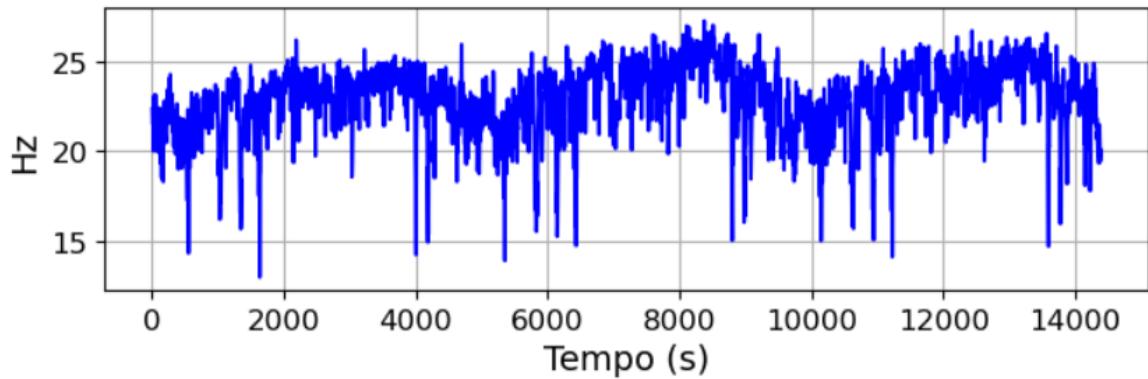
Uyanik, O. (2019). Estimation of the porosity of clay soils using seismic P- and S-wave velocities. *Journal of Applied Geophysics*, 170. doi: 10.1016/j.jappgeo.2019.103832

Yousefpour, N., & Fazel Mojtahedi, F. (2023). Early detection of internal erosion in earth dams: combining seismic monitoring and convolutional AutoEncoders. *Georisk*, 1–21. doi: 10.1080/17499518.2023.2251128

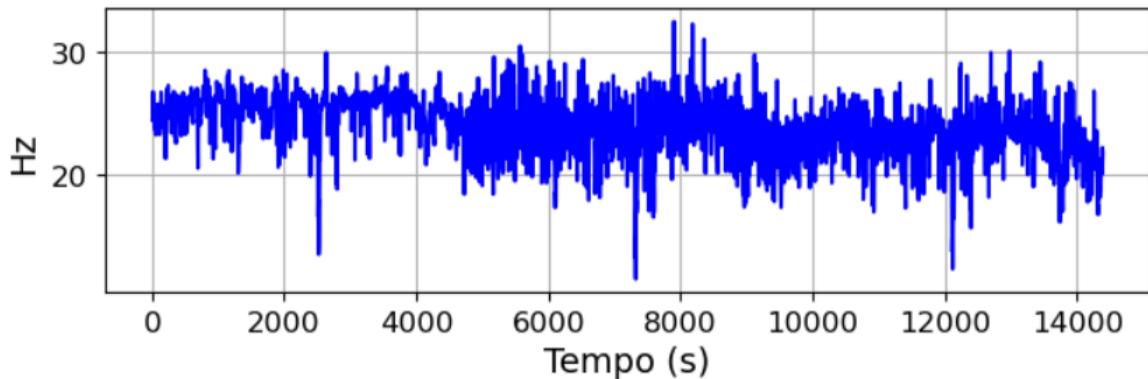
## 1. APÊNDICE A – ATRIBUTOS EXTRAÍDOS

Comportamento em função do tempo dos atributos extraídos, sendo eles: *Spectral Centroid*, *Spectral Bandwidth*, *Band Energy Ratio* (BER), *Zero Crossing Rate* (ZCR) a partir do monitoramento dos cenários de 1 a 5 e cenário dinâmico.



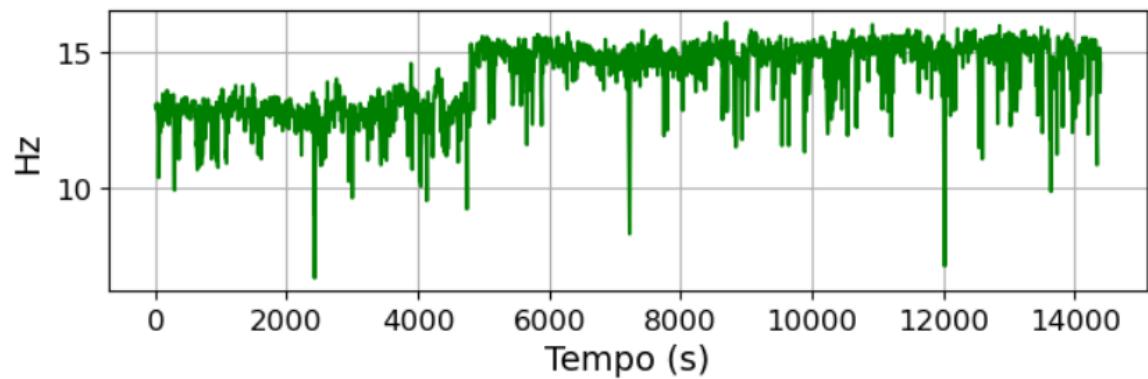


(d)



(e)

Figura 1.A – Representação do *Spectral Centroid* com os seguintes parâmetros: tamanho do quadro de análise (*frame size*) = 1024 e deslocamento da janela (*hop length*) = 512, aplicados aos cenários estáticos: (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4 e (e) cenário 5.



(a)

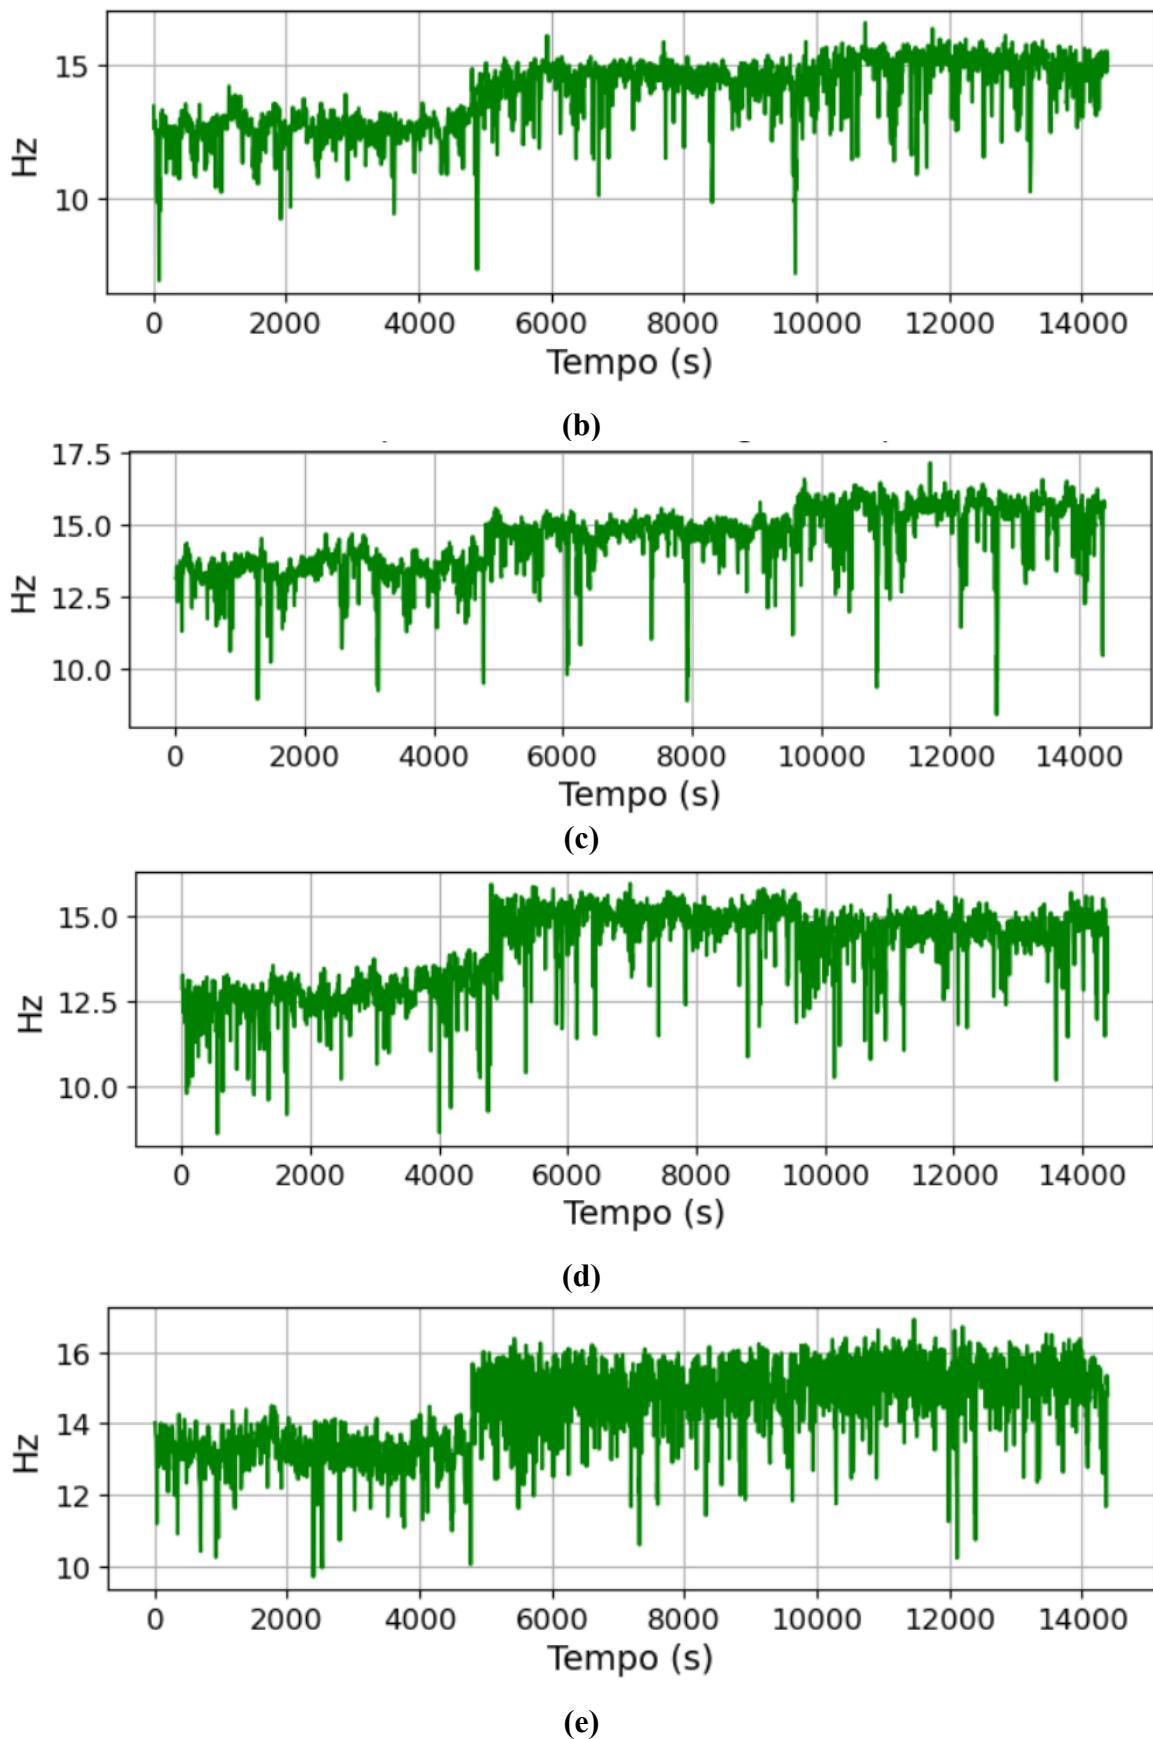
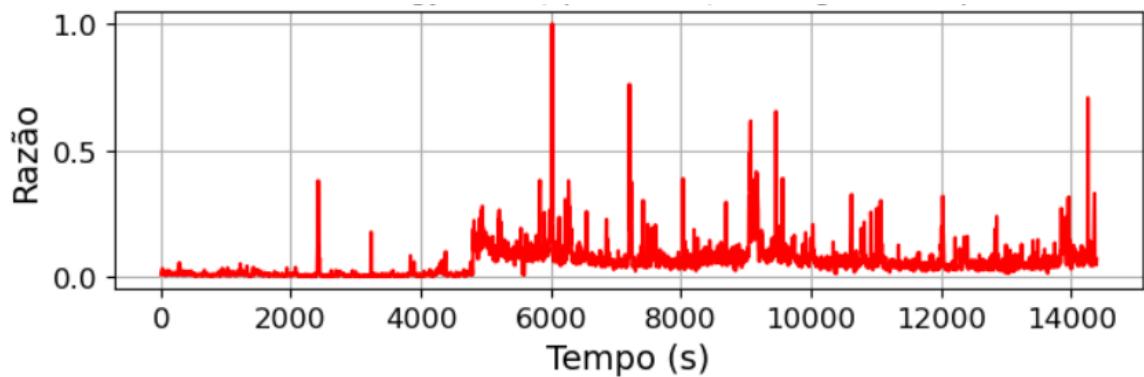
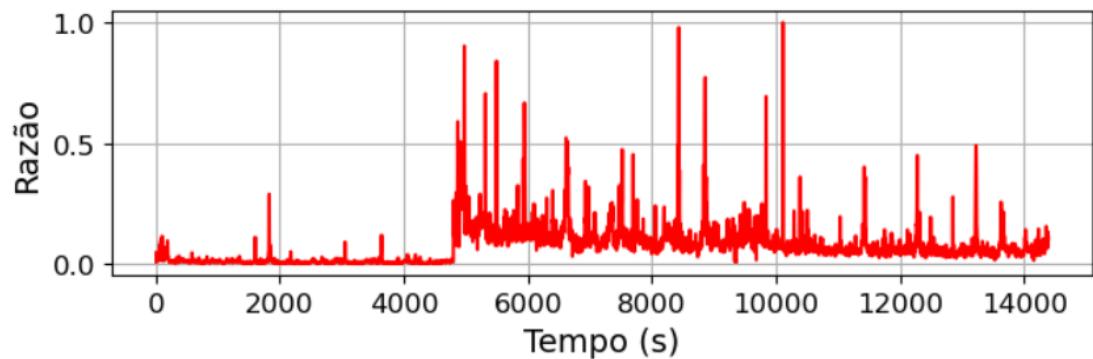


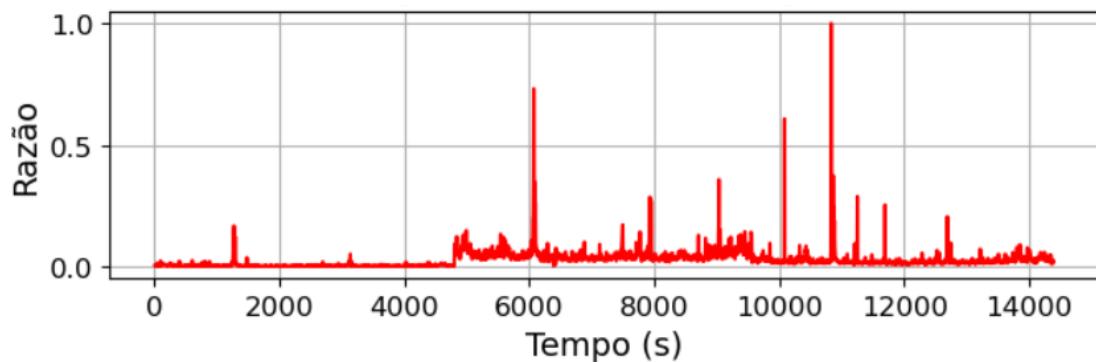
Figura 2.A – Representação do *Spectral Bandwidth* com os seguintes parâmetros: tamanho do quadro de análise (*frame size*) = 1024 e deslocamento da janela (*hop length*) = 512, aplicados aos cenários estáticos: (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4 e (e) cenário 5.



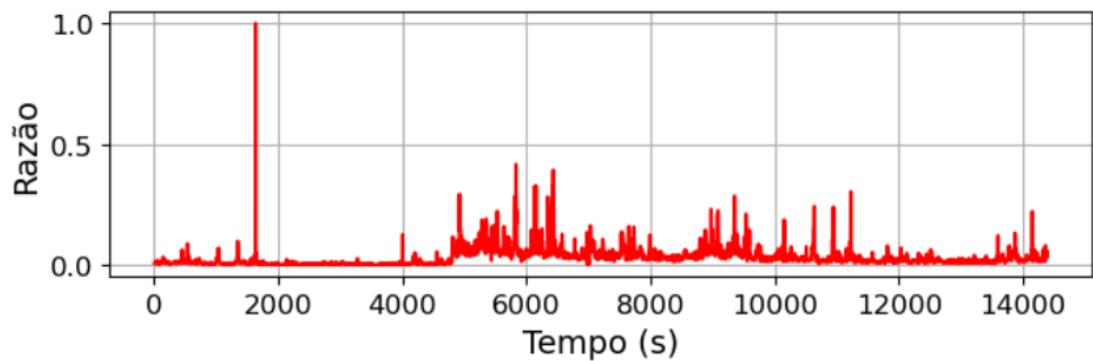
(a)



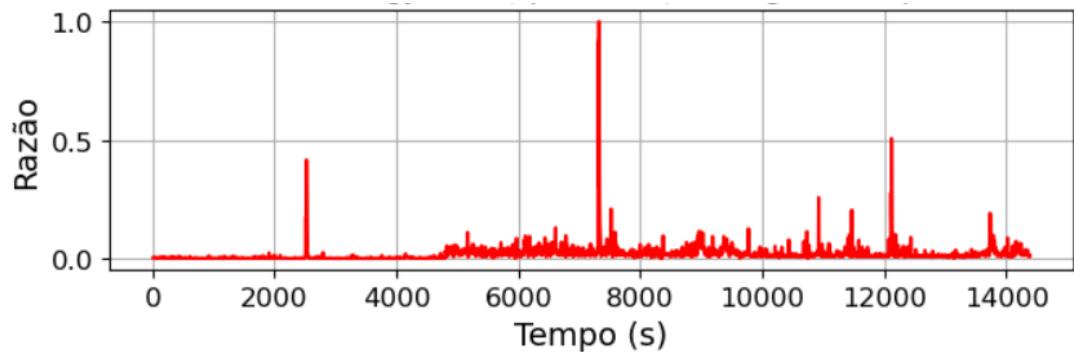
(b)



(c)

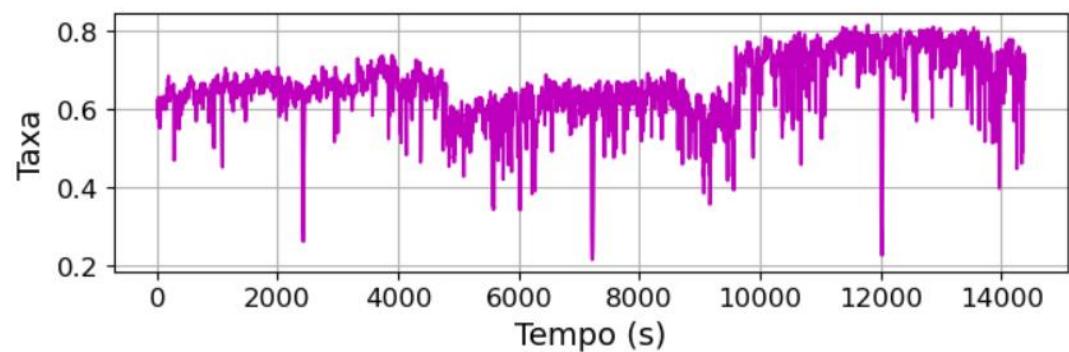


(d)

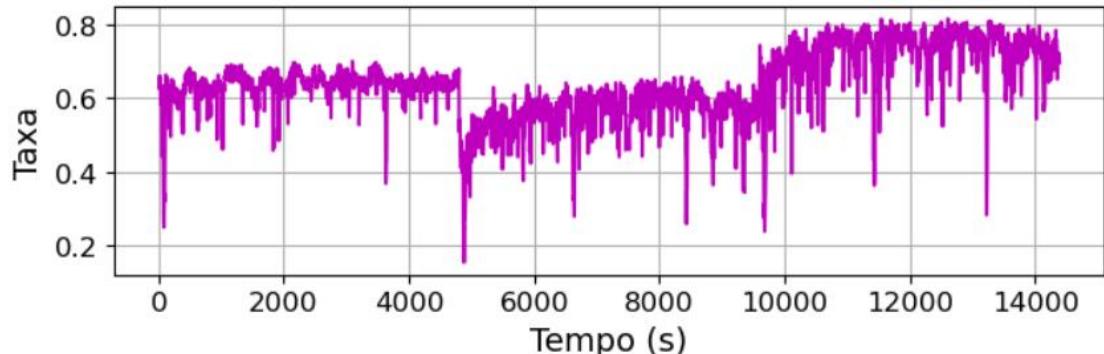


(e)

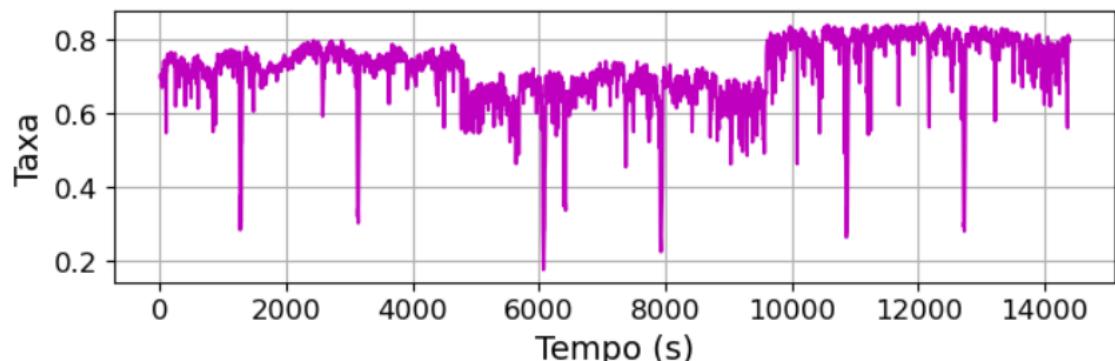
Figura 3.A – Representação do *Band Energy Ratio* (BER) normalizado com os seguintes parâmetros: tamanho do quadro de análise (*frame size*) = 1024 e deslocamento da janela (*hop length*) = 512, aplicados aos cenários estáticos: (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4 e (e) cenário 5.



(a)



(b)



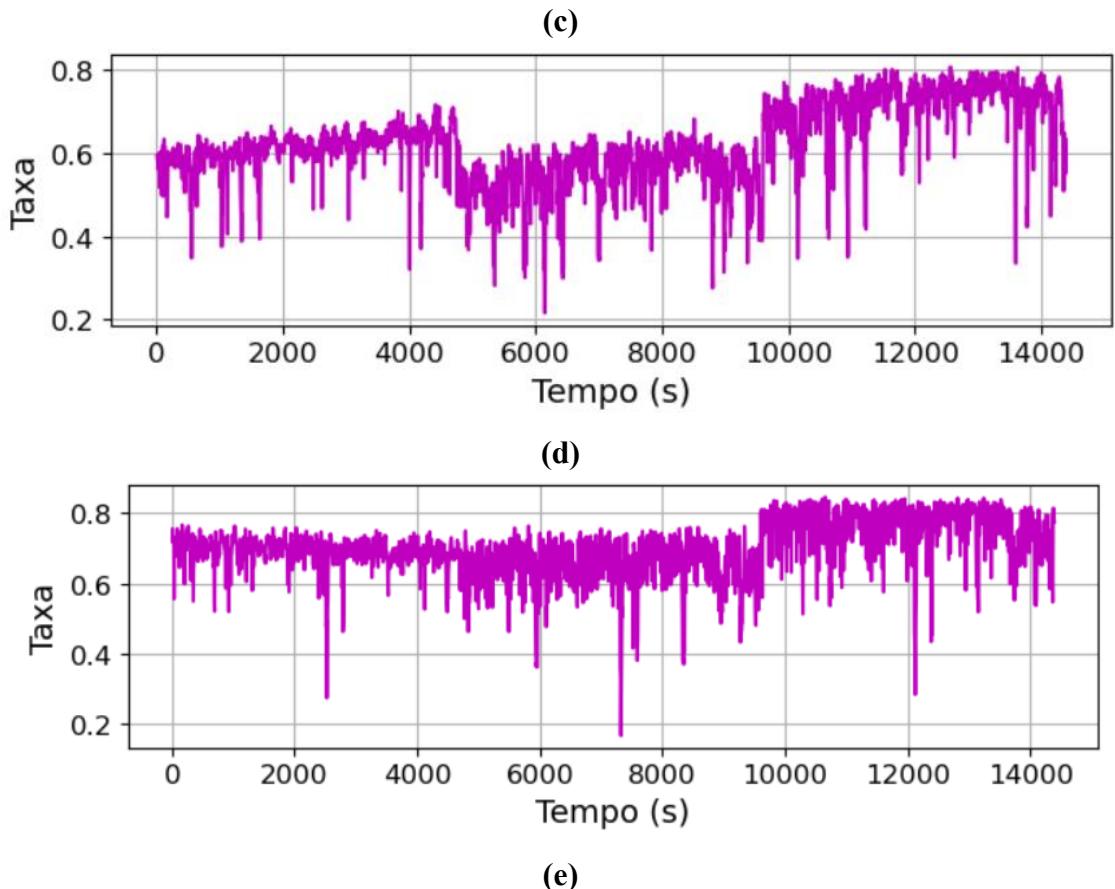


Figura 4.A – Representação do *Zero Crossing Rate* (ZCR) com os seguintes parâmetros: tamanho do quadro de análise (*frame size*) = 1024 e deslocamento da janela (*hop length*) = 512, aplicados aos cenários estáticos: (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4 e (e) cenário 5.

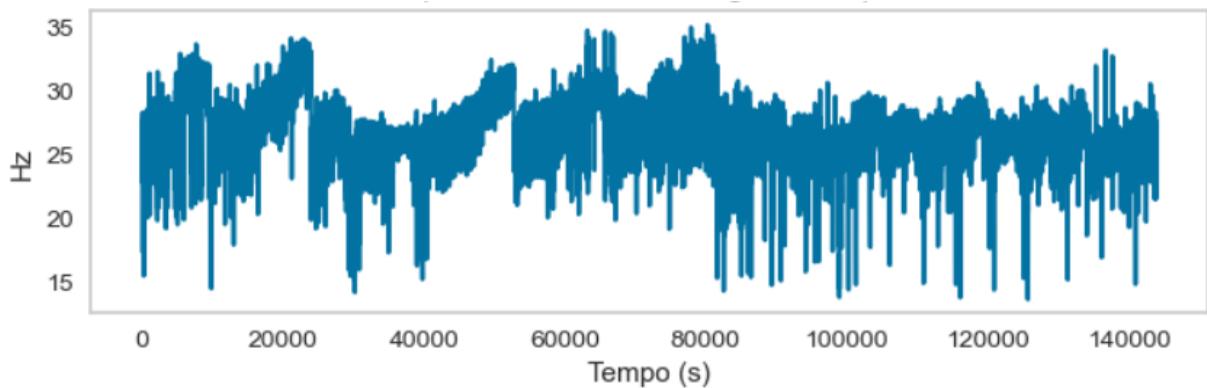


Figura 5.A – Representação do *Spectral Centroid* para o Cenário dinâmico, considerando 10 dias de monitoramento com os seguintes parâmetros: *frame size* (comprimento da janela de análise) = 1024 e *hop length* (deslocamento da janela de análise) = 512.

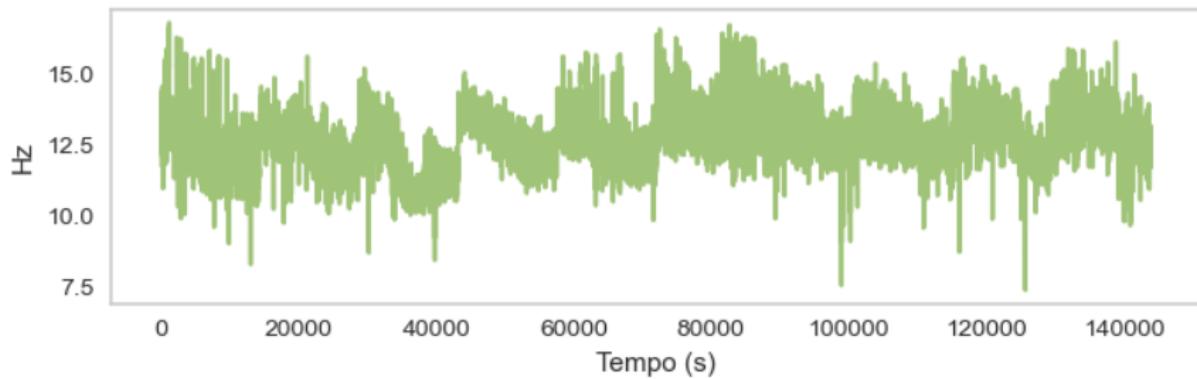


Figura 6.A – Representação do *Spectral Bandwidth* para o Cenário dinâmico, considerando 10 dias de monitoramento com os seguintes parâmetros: *frame size* (comprimento da janela de análise) = 1024 e *hop length* (deslocamento da janela de análise) = 512.

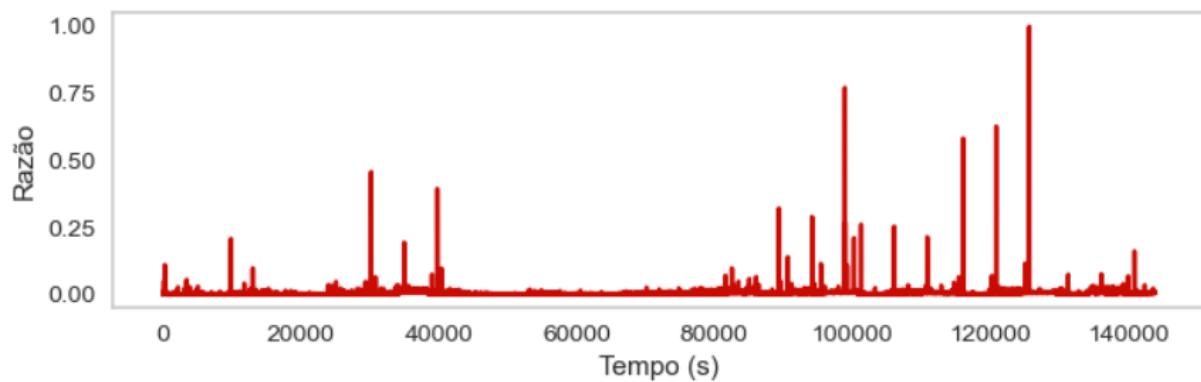


Figura 7.A – Representação do *Band Energy Ratio* (BER) normalizado para o Cenário dinâmico, considerando 10 dias de monitoramento com os seguintes parâmetros: *frame size* (comprimento da janela de análise) = 1024 e *hop length* (deslocamento da janela de análise) = 512.

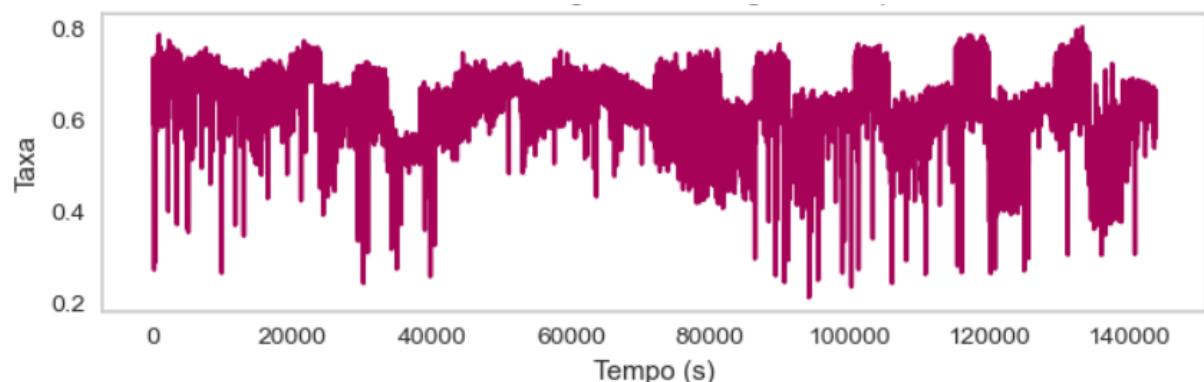


Figura 8.A – Representação do *Zero Crossing Rate* (ZCR) para o Cenário dinâmico, considerando 10 dias de monitoramento com os seguintes parâmetros: *frame size* (comprimento da janela de análise) = 1024 e *hop length* (deslocamento da janela de análise) = 512.

## 2. APÊNDICE B – MONITORAMENTO DOS CENÁRIOS



Figura 1.B – Início do monitoramento do Cenário 1.



Figura 2.B – Início do monitoramento do Cenário 2.



Figura 3.B – Início do monitoramento do Cenário 3.

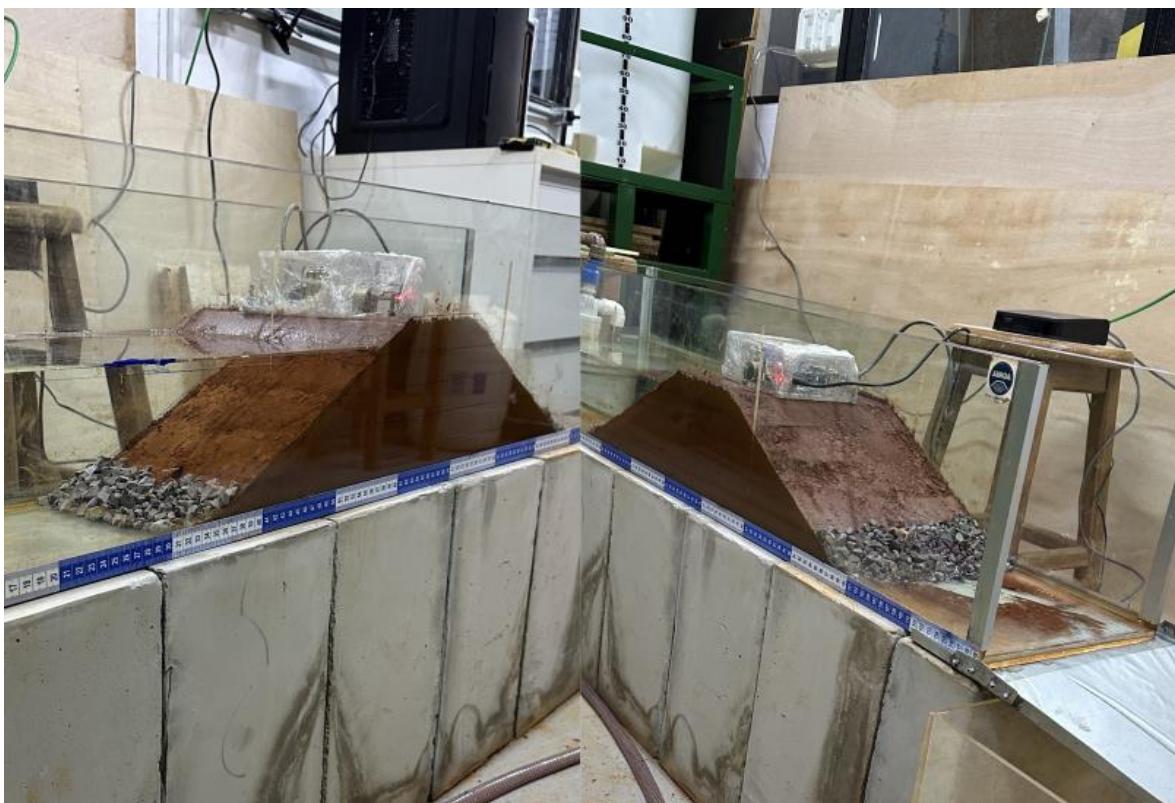


Figura 4.B – Início do monitoramento do Cenário 4.

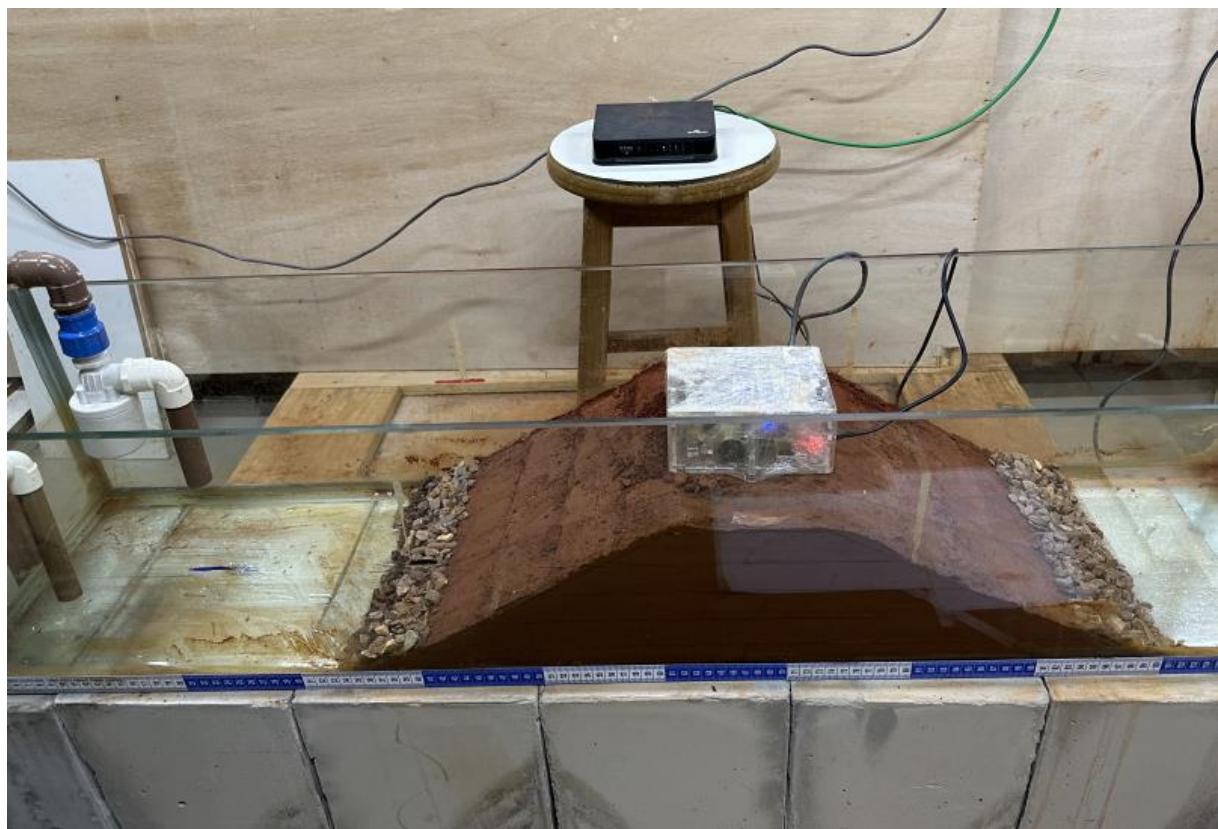


Figura 5.B – Início do monitoramento do Cenário 5.