



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
PRÓ-REITORIA DE GRADUAÇÃO
DEPARTAMENTO DE ENGENHARIAS
CURSO DE ENGENHARIA CIVIL

RAY PEREIRA FEITOSA LEAL

DESENVOLVIMENTO DE UM SISTEMA INTELIGENTE DE MONITORAMENTO
CONTÍNUO PARA DETECÇÃO DE PIPING EM BARRAGENS DE TERRA

CARAÚBAS

2025

RAY PEREIRA FEITOSA LEAL

DESENVOLVIMENTO DE UM SISTEMA INTELIGENTE DE MONITORAMENTO
CONTÍNUO PARA DETECÇÃO DE PIPING EM BARRAGENS DE TERRA

Monografia apresentada a Universidade
Federal Rural do Semi-Árido como requisito
para obtenção do título de Bacharel em
Engenharia civil.

Orientador: Prof. Ms. Francisco Felinto de
Lima Neto

Co-orientador: Profa. Dra. Adeline Marinho
Maciel

CARAÚBAS

2025

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei n° 9.279/1996 e Direitos Autorais: Lei n° 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

L435d Leal, Ray Pereira Feitosa.
Desenvolvimento de um sistema inteligente de monitoramento contínuo para detecção de piping em barragens de terra / Ray Pereira Feitosa Leal. - 2025.
69 f. : il.

Orientador: Francisco Felinto de Lima Neto.
Coorientadora: Adeline Marinho Maciel.
Monografia (graduação) - Universidade Federal Rural do Semi-árido, Curso de Engenharia Civil, 2025.

1. Barragens de terra. 2. Piping. 3. Monitoramento inteligente. 4. Machine learning. 5. Python. I. Lima Neto, Francisco Felinto de, orient. II. Maciel, Adeline Marinho, co-orient. III. Título.

Ficha catalográfica elaborada por sistema gerador automático em conformidade com AACR2 e os dados fornecidos pelo(a) autor(a).

Biblioteca Campus Caraúbas
Bibliotecária: Sarah Freire Bezerra
CRB: 15/1052

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

RAY PEREIRA FEITOSA LEAL

DESENVOLVIMENTO DE UM SISTEMA INTELIGENTE DE MONITORAMENTO
CONTÍNUO PARA DETECÇÃO DE PIPING EM BARRAGENS DE TERRA

Monografia apresentada a Universidade
Federal Rural do Semi-Árido como requisito
para obtenção do título de Bacharel em
Engenharia Civil.

Defendida em: 19 /12 /2025.

BANCA EXAMINADORA

Prof. Me. Francisco Felinto de Lima Neto
Presidente

Profa. Dra. Adeline Marinho Maciel
Membro Examinadora

Profa. Me. Karina Estrela Egídio
Membro Examinadora

Profa. Dra. Bianca Alencar Vieira
Membro Examinadora

DEDICATÓRIA

À memória de minha mãe, Maria Socorro Pereira da Silva, e de meu avô, Antonio Santino da Silva. Minha saudade diária e minha eterna gratidão. Tudo isso é por vocês e para vocês.

AGRADECIMENTOS

A esta etapa que se encerra, levo comigo a gratidão a todos que fizeram parte da minha história. Minha eterna gratidão aos meus familiares que a sua maneira contribuíra para a concretização deste momento. O incentivo de vocês foi o combustível para que eu chegasse até aqui. Obrigado por acreditarem!

Um agradecimento especial aos meus amigos, que estiveram ao meu lado em cada momento de ansiedade. Obrigado por ouvir meus desabafos, e por sempre me lembrar de que eu era capaz. Aos meus orientadores, Profa. Dra. Adeline Marinho Maciel e Prof. Ms. Francisco Felinto de Lima Neto, que foram essenciais para o desenvolvimento deste trabalho, também lhes agradeço pela paciência em alguns momentos tempestuosos na qual a chuva não parava de cair.

Principalmente, dedico este momento e toda pompa que ele traz a minha falecida mãe que há muito esperava por esse dia, e, que infelizmente não poderá celebra-lo, também estendendo ao meu querido avô, que na maior parte de minha vida se comportou mais como um pai, então, este momento é para vocês.

ÉPIGRAFE

"As flores brotam e morrem... As estrelas brilham, mas um dia se apagarão... Tudo morre... A Terra, o Sol, a Via Láctea e até mesmo todo este universo não é exceção! Comparado a isso, a vida do homem é tão breve e fugidia quanto um piscar de um olho. Nesse curto instante, os homens nascem, riem, choram, lutam, sofrem, festejam, lamentam, odeiam pessoas e amam outras. Tudo é transitório. E, em seguida, todos caem no sono eterno chamado morte."

Shaka de Virgem

RESUMO

A segurança de barragens de terra representa um desafio para a engenharia geotécnica, sendo o fenômeno de piping (erosão interna) uma das principais causas de rupturas estruturais. Os métodos tradicionais de monitoramento, muitas vezes manuais e intermitentes, apresentam limitações na detecção precoce de anomalias hidráulicas complexas. O presente trabalho propõe o desenvolvimento de um sistema autônomo de monitoramento geotécnico voltado à detecção automática de piping, integrando conceitos de Internet das Coisas (IoT) e Inteligência Artificial. A metodologia consistiu na criação de um ambiente computacional em linguagem Python, utilizando um modelo ARX para simular séries temporais piezométricas e variáveis exógenas (chuva e nível de reservatório). Para a detecção de falhas, implementou-se um ensemble de algoritmos de Machine Learning composto por Autoencoder Variacional (Transformer VAE), Local Outlier Factor (LOF) e um classificador LightGBM. O sistema foi validado por meio de simulações de Monte Carlo e calibração baseada na métrica F2-Score. Os resultados demonstraram alta eficácia, alcançando Precisão e Recall de 99,33%, com uma taxa de falsos alarmes inferior a 0,10%. O modelo identificou corretamente tendências de longo prazo e variações abruptas de poropressão, distinguindo anomalias reais de ruídos operacionais. Conclui-se que a aplicação de inteligência artificial em dados de instrumentação automatizada viabiliza um monitoramento preditivo robusto, contribuindo significativamente para a mitigação de riscos e a segurança operacional de barragens.

Palavras-chave: barragens de terra; piping; monitoramento inteligente; machine learning; Python.

ABSTRACT

The safety of earth dams represents a critical challenge for geotechnical engineering, with the phenomenon of piping (internal erosion) being one of the main causes of structural failures. Traditional monitoring methods, often manual and intermittent, present limitations in the early detection of complex hydraulic anomalies. This work proposes the development of an autonomous geotechnical monitoring system aimed at the automatic detection of piping, integrating Internet of Things (IoT) and Artificial Intelligence concepts. The methodology consisted of creating a computational environment in Python language, using an ARX model to simulate piezometric time series and exogenous variables (rainfall and reservoir level). For fault detection, an ensemble of Machine Learning algorithms composed of Variational Autoencoder (Transformer VAE), Local Outlier Factor (LOF), and a LightGBM classifier was implemented. The system was validated through Monte Carlo simulations and calibration based on the F2-Score metric. The results demonstrated high efficacy, achieving Precision and Recall of 99.33%, with a false alarm rate lower than 0.10%. The model correctly identified long-term trends and abrupt pore pressure variations, distinguishing real anomalies from operational noise. It is concluded that the application of artificial intelligence in automated instrumentation data enables robust predictive monitoring, significantly contributing to risk mitigation and operational safety of dams.

Keywords: earth dams; piping; intelligent monitoring; machine learning; Python.

LISTA DE FIGURAS

Figura 1 - Barragem de terra homogênea	21
Figura 2- Processo de piping	23
Figura 3 - Piezômetro Casagrande.....	29
Figura 4 - Piezomentro de corda vibrante	30
Figura 5 - Geometria da barragem.....	41
Figura 6 - Fluxograma metodológico	49
Figura 7- Matriz de confusão.....	53
Figura 8 - Curvas ROC e precisão-revocação do LOF.....	55
Figura 9 - Curvas Precision-Recall (PR)	56
Figura 10 - Distribuição do score do Transformer	57
Figura 11 - Distribuição do score do modelo	58
Figura 12 - Variáveis importantes para a detecção.....	59
Figura 13 - Pontuação de confiança do modelo	61

LISTA DE QUADROS

Quadro 1 - Tipos de piezômetros	32
Quadro 2- Descrição das Features	59

LISTA DE TABELAS

Tabela 1 - Níveis de controle de gerenciamento de risco.....	35
Tabela 2- Métricas de desempenho	53
Tabela 3- Comparação de desempenho dos detectores	54
Tabela 4 - Resumo dos desempenhos das simulações.....	62

LISTA DE ABREVIATURAS E SIGLAS

Sigla	Significado
ABNT	Associação Brasileira de Normas Técnicas
ANA	Agência Nacional de Águas e Saneamento Básico
ANM	Agência Nacional de Mineração
ARX	<i>Auto-Regressive with Exogenous inputs</i> (Auto-Regressivo com Entradas Exógenas)
AUC	<i>Area Under the Curve</i> (Área Sob a Curva)
DPA	Dano Potencial Associado
IDE	<i>Integrated Development Environment</i> (Ambiente de Desenvolvimento Integrado)
IoT	<i>Internet of Things</i> (Internet das Coisas)
JSON	<i>JavaScript Object Notation</i>
LightGBM	<i>Light Gradient Boosting Machine</i>
LOF	<i>Local Outlier Factor</i> (Fator de Outlier Local)
LoRaWAN	<i>Long Range Wide Area Network</i>
LSTM	<i>Long Short-Term Memory</i> (Memória de Longo Prazo e Curto Prazo)
MQTT	<i>Message Queuing Telemetry Transport</i>
NBR	Norma Brasileira
PAE	Plano de Ação de Emergência
PNSB	Política Nacional de Segurança de Barragens
PR	<i>Precision-Recall</i> (Precisão-Revocação)
PSB	Plano de Segurança de Barragens
RNA	Redes Neurais Artificiais
ROC	<i>Receiver Operating Characteristic</i> (Característica de Operação do Receptor)

TARP	<i>Trigger Action Response Plan</i>
UFERSA	Universidade Federal Rural do Semi-Árido
VAE	<i>Variational Autoencoder</i> (Autoencoder Variacional)
VSCode	Visual Studio Code
VWP	<i>Vibrating Wire Piezometer</i> (Piezômetro de Corda Vibrante)
YAML	<i>YAML Ain't Markup Language</i>

LISTA DE SÍMBOLOS

Símbolo	Significado
c'	Coesão efetiva do solo
ct	Vetor de memória da célula LSTM
D15	Diâmetro correspondente a 15% da massa passante na curva granulométrica
D85	Diâmetro correspondente a 85% da massa passante na curva granulométrica
e	Índice de vazios
E	Erro de reconstrução (Autoencoder)
f(x)	Função de estimativa de comportamento esperado
F1	F1-Score (Média harmônica entre precisão e revocação)
FN	Falsos Negativos
FP	Falsos Positivos
FS	Fator de Segurança
G	Peso específico relativo dos grãos (Gs)
h	Carga hidráulica total
ht	Vetor de saída/estado oculto da célula LSTM
i	Gradiente hidráulico
ic	Gradiente crítico
k	Coeficiente de permeabilidade do solo
L	Distância entre pontos de medição de pressão
ot	Vetor de saída da porta de saída (LSTM)
P	Precisão (Precision)
q	Vazão do fluxo
R	Revocação (Recall)
S	Grau de saturação

Símbolo	Significado
TP	Verdadeiros Positivos
u	Pressão neutra (poropressão)
z	Cota geométrica (carga de posição)
β	Parâmetro Beta (ponderação da métrica F-Score)
γ_{sat}	Peso específico saturado do solo
γ_w	Peso específico da água
Δ	Delta (Diferença ou variação de uma grandeza)
Δh	Diferença de carga hidráulica
λ	Lambda (Limiar de decisão para anomalia)
σ	Tensão total
σ'	Tensão efetiva
τ	Resistência ao cisalhamento do solo
ϕ'	Ângulo de atrito interno efetivo

SUMÁRIO

1	INTRODUÇÃO	18
1.1	OBJETIVOS	20
1.1.1	Objetivo geral.....	20
1.1.2	Objetivos específicos.....	20
2	REFERENCIAL TEÓRICO	21
2.1	Barragens de terra e o fenômeno de piping	21
2.2	Aspectos geotécnicos	25
2.3	Parâmetros geotécnicos e comportamento hidráulico.....	27
2.4	Diretrizes normativas e resoluções aplicáveis	27
2.5	Instrumentação geotécnica e piezometria	28
2.6	Níveis de controle e segurança de barragens	34
2.7	Monitoramento inteligente de barragens: integração IoT e inteligência artificial	37
2.7.1	Arquitetura IoT para monitoramento geotécnico	37
2.7.2	Inteligência Artificial e Machine Learning	38
2.7.3	Deteccção de anomalias	38
3	METODOLOGIA	40
3.1	Tipo de Pesquisa	40
3.2	Procedimentos metodológicos	40
3.2.1	Levantamento teórico	40
3.2.2	Definição dos parâmetros e variáveis.....	41
3.2.3	Desenvolvimento do ambiente computacional	43
3.2.4	Simulação da barragem	44
3.2.5	Processamento dos dados	45
3.2.6	Aplicação dos algoritmos de deteccção de anomalias	47
3.2.7	Avaliação de desempenho	48
3.2.8	Fluxograma metodológico.....	49
3.3	Ferramentas utilizadas	50
4	RESULTADOS E DISCUSSÃO	52
4.1	Desempenho global do sistema de deteccção	52
4.2	Desempenho dos detectores individuais e métricas AUC	53
4.3	Curvas PR/ROC do modelo e escolha do limiar.....	55

4.4	Distribuição dos scores de anomalia.....	56
4.5	Importância das variáveis e interpretação física	58
4.6	Monitoramento em modo replay e séries temporais	61
4.7	Robustez, Monte Carlo e reprodutibilidade	62
4.8	Erros residuais e limitações observadas.....	63
5	CONCLUSÃO	64
	REFERÊNCIAS	66

1 INTRODUÇÃO

A segurança de barragens de terra representa-se como um dos desafios da engenharia geotécnica moderna, especialmente devido ao risco associado à ocorrência do fenômeno de piping, um processo de erosão interna progressiva causado pelo fluxo de água através de poros ou fissuras no maciço. Esse mecanismo pode levar à formação de canais subterrâneos, resultando na perda de material e possível ruptura da estrutura, configurando-se como uma das principais causas de falhas em barragens de solo homogêneo (Barros, 2020).

De acordo com estudos recentes, a detecção precoce de anomalias relacionadas ao piping é fundamental para evitar desastres com consequências humanas, econômicas e ambientais graves Silva e Garcia (2025). Contudo, os métodos tradicionais de monitoramento (geralmente baseados em leituras manuais e análise visual de dados) apresentam limitações quanto à frequência de coleta e à capacidade de identificar padrões complexos e anomalias contextuais (Bragioni, 2022; Ribeiro, 2023).

Nesse contexto, a instrumentação geotécnica automatizada, especialmente com o uso de piezômetros elétricos e sensores conectados, permite a coleta contínua de dados de poropressão, fornecendo informações essenciais sobre o comportamento hidráulico do maciço (Barros, 2020). Entretanto, a simples aquisição de dados não é suficiente: é necessário interpretá-los de maneira inteligente e em tempo real, a fim de identificar tendências de infiltração e aumento anômalo de pressão que possam indicar o início de um processo de piping).

A integração de tecnologias emergentes como a Internet das Coisas (IoT) e o aprendizado de máquina (Machine Learning) vem transformando a forma como as barragens são monitoradas. Andrade *et al.* (2018) apresentam o uso de redes LoRaWAN (*Long Range Wide Area Network*) para transmissão de dados de sensores em tempo real, viabilizando monitoramento contínuo e de baixo custo energético em grandes áreas. Da mesma forma, Yaqoob *et al.* (2017) e Ghosh, Edwards e Hosseini (2020) destacam a aplicação da IoT na engenharia civil como base para sistemas inteligentes de gestão de infraestrutura, capazes de coletar, transmitir e processar grandes volumes de dados de forma integrada.

Com o avanço da inteligência artificial, modelos de aprendizado profundo como redes neurais artificiais (RNA) e autoencoders vêm sendo aplicados para detectar anomalias em séries temporais de instrumentação de barragens. Irazábal *et al.* (2025) demonstraram que autoencoders podem identificar com precisão outliers em séries de dados de piezômetros e medidores de vazão, reduzindo falsos positivos e aumentando a confiabilidade das análises. Em abordagem semelhante, Silva e Garcia (2025) utilizaram o algoritmo Local Outlier Factor

(LOF) para detectar anomalias geradas sinteticamente em dados de piezômetros, obtendo F1-Score de 0,868 e precisão de 100%, superando métodos estatísticos tradicionais como boxplot e regressão linear.

Diante desse cenário, o presente trabalho propõe o desenvolvimento de um sistema inteligente de monitoramento piezométrico voltado à detecção automática de anomalias de piping. O sistema utiliza sensores conectados via LoRaWAN para a transmissão dos dados e algoritmos de Machine Learning para análise de padrões e identificação de desvios característicos do início de processos de erosão interna. O objetivo é contribuir para a evolução da segurança de barragens, fornecendo uma solução capaz de operar de forma autônoma, contínua e em tempo real, integrando princípios de geotecnia, instrumentação, IoT e inteligência artificial.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Propor e desenvolver um sistema autônomo de monitoramento geotécnico para a detecção automática de anomalias associadas ao fenômeno de piping em barragens de terra, baseado na integração de instrumentação piezométrica, (IoT) e algoritmos de Machine Learning.

1.1.2 Objetivos específicos

- Realizar um levantamento de bases de dados públicas relacionadas à segurança e ao monitoramento de barragens, a fim de verificar a disponibilidade de registros reais de falhas e identificar limitações quanto ao acesso e à qualidade dos dados;
- Desenvolver um sistema computacional em Python para o monitoramento contínuo de barragens de terra, utilizando dados de piezômetros e informações hidrológicas;
- Definir os parâmetros e variáveis necessários para representar o comportamento hidráulico da barragem em condições normais e em situações associadas ao fenômeno de piping;
- Gerar dados sintéticos por meio de simulações, com o objetivo de representar cenários de operação e de falha da barragem;
- Propor e aplicar uma arquitetura de detecção de anomalias baseada em aprendizado de máquina, utilizando uma abordagem de ensemble, visando identificar indícios do fenômeno de piping nos dados simulados;
- Avaliar o desempenho do sistema proposto a partir dos dados simulados, verificando sua capacidade de identificar anomalias de forma eficiente.


2 REFERENCIAL TEÓRICO

2.1 Barragens de terra e o fenômeno de piping

As barragens de terra são obras geotécnicas destinadas à contenção de água, rejeitos ou resíduos industriais, construídas predominantemente com materiais terrosos compactados. Elas apresentam, segundo Ribeiro (2023), grande relevância socioeconômica, pois garantem o abastecimento de água, geração de energia e disposição segura de rejeitos minerais. No entanto, seu comportamento estrutural depende fortemente das condições de permeabilidade e resistência dos solos empregados, o que torna o controle do fluxo interno um aspecto essencial para a segurança da estrutura.

De acordo com Bragioni (2022), as barragens de terra são classificadas em três tipos principais: homogêneas, zoneadas e de enrocamento. Nas homogêneas, o corpo da barragem é constituído por um único tipo de material (Figura 1); nas zoneadas, há um núcleo de baixa permeabilidade, geralmente argiloso, confinado por filtros e drenos; e nas de enrocamento, o maciço é composto por blocos de rocha e o núcleo argiloso atua como elemento de vedação. Em todas essas tipologias, o equilíbrio entre pressão de água e resistência do solo é determinante para evitar processos de instabilidade interna.

Figura 1 - Barragem de terra homogênea



Fonte: Inova Civil (2019)


O comportamento hidráulico do solo que compõe a barragem pode ser descrito pela Lei de Darcy, segundo a qual a vazão do fluxo (q) é proporcional ao gradiente hidráulico (i), de acordo com a Equação 1,

$$q = k \cdot i \quad (1)$$

em que k é o coeficiente de permeabilidade do solo. Valores elevados de i ou k indicam maior facilidade de percolação e, em consequência, maior potencial para o surgimento de anomalias hidráulicas. Como destaca Barros (2020), o controle dessas grandezas é vital em estruturas homogêneas, pois nelas a ausência de filtros ou drenos facilita a concentração de fluxo em trajetórias preferenciais.

O fenômeno conhecido como piping está associado justamente a esse desequilíbrio hidráulico. Segundo Barros (2020) e Ribeiro (2023), o piping consiste em um processo de erosão interna regressiva causado pelo fluxo de água através de solos saturados, capaz de remover partículas finas e formar canais de percolação, como apresentado na Figura 2. Esse processo, inicialmente microscópico, tende a se ampliar progressivamente até comprometer o corpo da barragem. Trata-se de uma das principais causas de ruptura em barragens de terra, responsável por mais de 40 % das falhas documentadas em estudos internacionais (Irazábal *et al.* 2025).

Figura 2- Processo de piping



Fonte: (USACE, 2014, apud Lara, 2016, p. 46)

O piping desenvolve-se quando o gradiente hidráulico efetivo ultrapassa o gradiente crítico do solo, valor no qual o peso das partículas é compensado pela força de percolação ascendente. O gradiente crítico (i_c) pode ser calculado de acordo com a Equação 2,

$$i_c = (G_s - 1) / (1 + e) \quad (2)$$

onde G_s é o peso específico relativo dos grãos e e é o índice de vazios (Craig, 2012). Conforme Ribeiro (2023), o processo de piping pode ser dividido em quatro estágios: (1) início da erosão, com migração de partículas finas; (2) desenvolvimento de um canal de fluxo preferencial; (3) retrocesso do canal em direção à montante; e (4) ruptura global do maciço. A partir do segundo estágio, a elevação da poropressão é geralmente detectada por piezômetros, tornando-se um indicador inicial da anomalia.

Robertson *et al.*, (2019) descreve comportamento atípico da instrumentação, em que diversos piezômetros registraram aumentos irregulares de carga piezométrica nos meses anteriores ao rompimento. Alguns instrumentos apresentaram leituras anômalas e inconsistentes com as condições operacionais esperadas, sinalizando possível perda de eficácia dos sistemas de drenagem interna.

Casos documentados, como o da Barragem de Greenhills Operations (2021), demonstram o papel fundamental da instrumentação na prevenção do piping. Nesse empreendimento, leituras contínuas de piezômetros elétricos e inclinométricos permitiram identificar gradientes hidráulicos em elevação e tomar medidas preventivas antes que o processo se intensificasse. O relatório indica que, durante o período de operação 2020–2021, nenhum evento de erosão interna foi registrado, comprovando a eficácia do sistema de monitoramento.

O fenômeno também é fortemente influenciado pelas características construtivas e geológicas da barragem. Solos com granulometria mal graduada ou presença de camadas intercaladas de materiais de permeabilidades contrastantes favorecem a concentração do fluxo (Ribeiro, 2023). Além disso, fissuras geradas por recalques diferenciais ou secagem superficial podem atuar como condutos preferenciais para o escoamento. Gacu *et al.* (2025) acrescentam que fatores climáticos, como ciclos de saturação e ressecamento, alteram a condutividade hidráulica e podem acelerar a progressão do fenômeno.

Do ponto de vista da mecânica dos solos, o piping ocorre quando as tensões efetivas (σ') se reduzem a zero. A tensão efetiva é definida como mostra a Equação 3,

$$\sigma' = \sigma - u \quad (3)$$

em que σ é a tensão total e u é a pressão neutra. Assim, à medida que a poropressão aumenta, a resistência ao cisalhamento do solo ($\tau = c' + \sigma' \cdot \tan \phi'$) diminui. Quando $\sigma' \rightarrow 0$, o material perde sustentação e ocorre o arraste de partículas. Esse mecanismo explica por que o controle de poropressão é o parâmetro mais sensível na prevenção do piping.

Robertson *et al.*, (2019) e o documento de desempenho anual da Barragem de Greenhills Operations (2021) reforçam que as regiões mais suscetíveis ao fenômeno são o contato entre o núcleo e o dreno, a fundação e as ombreiras. Nessas áreas, a combinação de gradiente alto e solos mais permeáveis gera fluxos ascendentes intensos. A instrumentação deve, portanto, concentrar-se nesses setores críticos, garantindo a detecção precoce de variações de pressão.

A literatura internacional recente aponta para o uso de técnicas numéricas de simulação do fluxo em meio poroso, como o método dos elementos finitos aplicado em programas como SEEP/W e Slide2, utilizados por Ribeiro (2023). Esses modelos permitem correlacionar as leituras de campo com as condições simuladas de fluxo e estabilidade, possibilitando a definição de faixas de risco piezométrico mais precisas.

Por fim, o estudo de Silva e Garcia (2025) mostra que o fenômeno de piping não pode ser tratado apenas sob o ponto de vista físico, mas também como um problema de detecção de anomalias em dados de instrumentação. O monitoramento contínuo, aliado a métodos de machine learning, permite identificar padrões de pressão que antecedem a instabilidade. A análise conjunta entre a mecânica dos solos e as ferramentas computacionais constitui, portanto, a base para um sistema de monitoramento inteligente e preventivo.

2.2 Aspectos geotécnicos

O desempenho estrutural e hidráulico de uma barragem de terra está intrinsecamente ligado às propriedades geotécnicas dos materiais utilizados na sua construção. A seleção adequada dos solos, aliada a técnicas de compactação e controle de qualidade, é decisiva para garantir a estabilidade física, a segurança hidráulica e a durabilidade da estrutura (Barros, 2020).

Segundo Ribeiro (2023), a barragem pode ser entendida como um sistema geotécnico complexo, composto por materiais heterogêneos e anisotrópicos, cujo comportamento é governado por interações entre tensões efetivas, poropressões, gradientes hidráulicos e deformações. Assim, compreender as propriedades fundamentais (permeabilidade, resistência ao cisalhamento, compressibilidade e estabilidade de taludes) é essencial para prever e monitorar o desempenho da estrutura ao longo de sua vida útil.

Conforme a classificação apresentada na seção anterior, a escolha dos materiais é definida pela função estrutural e hidráulica de cada zona (núcleo, filtros ou taludes), exigindo propriedades geotécnicas específicas para cada caso. Em todos os casos, a escolha do material é definida conforme a função estrutural e hidráulica de cada zona: impermeabilização, suporte, drenagem ou proteção superficial.

a) Solos argilosos

Os solos argilosos são os principais constituintes de núcleos impermeáveis. Apresentam baixa permeabilidade ($k < 10^{-7}$ m/s) e alta coesão, mas elevada compressibilidade e plasticidade (Craig, 2012). Tais características resultam da predominância de partículas finas, geralmente menores que 0,002 mm, e da elevada capacidade de adsorção de água.

A compactação adequada, com teor de umidade próximo à ótima determinada pelo ensaio Proctor, reduz significativamente a condutividade hidráulica e aumenta a resistência ao cisalhamento (Barros, 2020). Entretanto, variações volumétricas provocadas por ciclos de secagem e saturação podem gerar fissuras que favorecem a percolação e a erosão interna.

O controle de compactação e a aplicação de revestimentos drenantes laterais são estratégias indispensáveis para garantir o desempenho hidráulico e evitar o surgimento de canais de percolação preferencial (Ribeiro, 2023).

b) Solos arenosos

Os solos arenosos são amplamente utilizados em filtros e drenos, devido à sua elevada permeabilidade ($k \approx 10^{-3}$ a 10^{-5} m/s) e baixa compressibilidade. Apresentam comportamento predominantemente granular e não coesivo, com resistência ao cisalhamento dominada pelo ângulo de atrito interno (ϕ') (Craig, 2012).

A seleção granulométrica é importante, pois define o comportamento de transição com as zonas argilosas. O filtro deve obedecer aos critérios clássicos de Terzaghi, garantindo que o diâmetro efetivo (D_{15}) do filtro seja compatível com o diâmetro D_{85} do material protegido, evitando tanto o entupimento quanto a migração de finos (Craig, 2012).

A função dos filtros e drenos é interromper o gradiente hidráulico, permitir o escoamento seguro da água e prevenir o início de piping. A ruptura de filtros é uma das causas mais frequentes de falhas em barragens, como observado por Robertson *et al.*, (2019), em que a saturação excessiva do rejeito e o comprometimento dos drenos contribuíram para a instabilidade do maciço.

c) Materiais de enrocamento

O enrocamento é formado por blocos de rocha compactados, caracterizados por alta resistência mecânica, elevada permeabilidade e baixa compressibilidade. É empregado em espaldares e taludes de jusante, fornecendo estabilidade global e capacidade drenante.

2.3 Parâmetros geotécnicos e comportamento hidráulico

A Lei 12.334/2010, que institui a Política Nacional de Segurança de Barragens (PNSB), determina que o controle da percolação e a avaliação das condições geotécnicas constituem parâmetros obrigatórios de segurança. A Resolução ANA nº 236/2017, art. 10, exige que todo Plano de Segurança de Barragens (PSB) contenha a caracterização geotécnica dos materiais e os parâmetros obtidos em ensaios de campo e laboratório.

As condições de fluxo também são analisadas por meio de modelagens numéricas, como o SEEP/W e o FLAC, que permitem estimar o campo de pressões neutras e o comportamento de saturação ao longo do tempo. Ribeiro (2023), ao calibrar modelos de fluxo e estabilidade em duas seções de barragens de rejeitos, demonstrou que a linha de saturação tende a se elevar quando a condutividade hidráulica é reduzida artificialmente em camadas de base, fato que reduz o fator de segurança (FS) de 1,5 para 1,1.

2.4 Diretrizes normativas e resoluções aplicáveis

Os principais instrumentos legais e normativos que regem os aspectos geotécnicos e de segurança em barragens no Brasil são:

- Lei nº 12.334/2010 – Política Nacional de Segurança de Barragens (BRASIL, 2010);
- Resolução ANA nº 236/2017 – Diretrizes para o Plano de Segurança de Barragens (BRASIL, 2017);
- Resolução ANA nº 91/2012 – Classificação de barragens quanto ao Dano Potencial Associado – DPA (BRASIL, 2012);
- Resolução ANA nº 143/2012 – Estrutura mínima dos Relatórios de Segurança de Barragens (BRASIL, 2012);
- Resolução ANM nº 32/2020 – Requisitos técnicos e prazos para descaracterização de barragens alteadas a montante (BRASIL, 2020);
- ABNT NBR 13028:2017 – Estabilidade de taludes (ABNT, 2017);
- ABNT NBR 11682:2009 – Estabilidade de encostas naturais e taludes (ABNT, 2009);
- ABNT NBR 8681:2021 – Ações e segurança nas estruturas (ABNT, 2021);
- ABNT NBR 6484:2020; NBR 7182:2021; NBR 14545:2000 – Ensaios geotécnicos para caracterização dos materiais (ABNT, 2000; ABNT, 2020; ABNT, 2021).

Essas normas e resoluções compõem o arcabouço técnico que orienta os critérios de projeto, execução, instrumentação e operação das barragens de terra no país, assegurando a rastreabilidade dos parâmetros geotécnicos ao longo do ciclo de vida do empreendimento.

2.5 Instrumentação geotécnica e piezometria

O monitoramento da segurança de barragens depende fundamentalmente da instrumentação geotécnica, cujo objetivo é medir parâmetros físicos e hidráulicos que descrevem o comportamento interno do maciço. Entre os instrumentos mais utilizados estão os piezômetros, inclinômetros, medidores de nível d'água, drenos instrumentados e marcos de recalque, que em conjunto fornecem uma visão integrada do desempenho estrutural e hidráulico da barragem (Ribeiro, 2023).

Segundo Bragioni (2022), a instrumentação representa o elo entre a engenharia de projeto e a operação da barragem, permitindo a identificação de desvios antes que estes evoluam para falhas. Os piezômetros, em especial, são instrumentos essenciais para o controle de poropressões no interior da estrutura e para a avaliação de gradientes hidráulicos, grandezas diretamente associadas ao risco de piping.

O piezômetro mede a pressão neutra (u) da água nos poros do solo, possibilitando determinar a carga hidráulica total (h), conforme a Equação 4.

$$h = z + (u / \gamma_w) \quad (4)$$

Deste modo temos que z é a cota geométrica do ponto de medição (m) e γ_w é o peso específico da água (9,81 kN/m³). A diferença de carga entre dois piezômetros próximos (Δh) permite estimar o gradiente hidráulico (i), ver Equação 5,

$$i = \Delta h / L \quad (5)$$

onde L é a distância entre as tomadas de pressão. Valores elevados de i podem indicar percolação intensa ou falha na drenagem interna.

O monitoramento piezométrico constitui um dos elementos centrais da instrumentação geotécnica em barragens de terra e de rejeitos. Através dele é possível acompanhar a variação das pressões neutras e da linha de saturação interna, parâmetros diretamente relacionados à estabilidade global da estrutura (Machado, 2007).


Entre os instrumentos utilizados para esse fim, destacam-se três principais tipos de piezômetros, que se diferenciam quanto ao princípio de funcionamento, à precisão, ao método de leitura e ao custo de instalação: piezômetro de tubo aberto (Casagrande), piezômetro elétrico de corda vibrante (VWP) e piezômetro de transdutor de pressão (strain gauge) (Machado, 2007; Ribeiro, 2023).

O método continua sendo amplamente empregado como instrumento de referência para calibração e comparação de piezômetros automatizados, conforme relatado por Ribeiro (2023) em seu estudo sobre níveis de controle piezométricos.

De acordo com Machado (2007) o piezômetro elétrico de corda vibrante (VWP) é um equipamento de alta precisão utilizado para medições automáticas e contínuas de pressão intersticial, cujo princípio de funcionamento baseia-se na variação da frequência de vibração de um fio metálico tensionado — a “corda vibrante” — acoplado a um diafragma sensível à pressão da água.

Quando a poropressão atua sobre o diafragma, ocorre uma deformação que altera a tensão do fio, modificando sua frequência de vibração. Essa frequência é medida por uma bobina eletromagnética e convertida em unidades de pressão (kPa), que podem ser transmitidas digitalmente para um sistema de aquisição de dados (Machado, 2007). Na figura 4 está a representação de um piezômetro de corda vibrante:

Figura 4 - Piezômetro de corda vibrante



Fonte: Vale / Coffey (2016)

De acordo com Robertson *et al.*, (2019), vinte piezômetros de corda vibrante foram instalados entre dezembro de 2018 e janeiro de 2019. A partir de 10 de janeiro de 2019, 46 piezômetros automatizados passaram a transmitir dados ao sistema centralizado em intervalos de cinco minutos. O relatório destaca que esses dispositivos apresentam longa durabilidade e

capacidade de coletar leituras com alta frequência, além de poderem ser integrados a sistemas automatizados de monitoramento.

Ribeiro (2023) também cita o modelo VW2100 da RST Instruments, amplamente utilizado no Brasil, ilustrando sua aplicação em duas seções de barragens de rejeito. As leituras obtidas foram essenciais para estabelecer níveis de controle em condições normais, de atenção, alerta e emergência.

Segundo Bragioni (2022), as principais vantagens do VWP são:

- Alta precisão e estabilidade ao longo do tempo;
- Possibilidade de leitura remota e automatizada;
- Redução de erro humano e detecção imediata de variações abruptas de pressão neutra.

As limitações residem no custo mais elevado e na necessidade de calibração adequada, além da sensibilidade a interferências elétricas e variações de temperatura. Por esse motivo, em muitos projetos, o VWP é instalado em paralelo a piezômetros Casagrande, garantindo redundância e comparação entre medições manuais e automáticas.

Tratando-se do piezômetro de transdutor de pressão, também conhecido como *strain gauge piezometer*, mede a pressão de poros por meio da deformação elástica de um diafragma metálico equipada com galgas extensométricas (*strain gauges*). Quando o fluido exerce pressão sobre o diafragma, as galgas convertem essa deformação em variação de resistência elétrica, que é proporcional à pressão exercida (Machado, 2007).

Diferentemente do VWP, que utiliza o princípio de vibração, o transdutor de pressão opera com base em medições de deformação resistiva. Segundo Robertson *et al.*, (2019), esse tipo de instrumento foi usado em menor quantidade, mas com função complementar, permitindo leituras de pressão instantânea e de alta resolução, especialmente em zonas profundas do maciço e na fundação. O documento descreve que tais sensores foram integrados aos piezômetros automatizados e conectados a registradores de dados por telemetria.

Esses piezômetros são amplamente empregados em barragens modernas e projetos de pesquisa por apresentarem tempo de resposta extremamente rápido, sendo indicados para detectar eventos transitórios de variação de pressão — como sobrecargas súbitas, infiltrações localizadas ou resposta a chuvas intensas.

Conforme discutido por Silva, Caetano e Pierozan (2024), a interpretação estatística das leituras obtidas por transdutores de pressão pode revelar anomalias correlacionadas entre diferentes pontos instrumentados, permitindo identificar falhas localizadas de drenagem ou recalques diferenciais em tempo real.

As vantagens do *strain gauge* incluem a precisão, a possibilidade de calibração eletrônica e a compatibilidade com sistemas de aquisição contínua. Por outro lado, requerem proteção adequada contra variações de temperatura, interferências eletromagnéticas e corrosão, além de cuidados no manuseio do cabeamento e da vedação do diafragma. Um resumo é mostrado no Quadro 1:

Quadro 1 - Tipos de piezômetros

Tipo de piezometro	Princípio de funcionamento	Tipo de leitura	Vantagens principais	Limitações
Tubo aberto (Casagrande)	Equilíbrio hidrostático da coluna d'água no tubo	Manual, pontual	Simples, de baixo custo, fácil manutenção	Não fornece leituras contínuas, dependente de operador
Elétrico de corda vibrante (VWP)	Variação de frequência de um fio tensionado conforme pressão	Automática e contínua	Alta precisão, leitura remota, ideal para AIoT	Custo elevado, sensível à temperatura
Transdutor de pressão (Strain Gauge)	Deformação do diafragma medida por galgas extensométricas	Automática, alta resolução	Resposta rápida, detecta variações transitórias	Exige calibração e proteção elétrica

Fonte: Adaptado de Bragioni (2022)

Robertson *et al.*, (2019), descreve a instalação de 123 piezômetros, sendo 49 deles convertidos em sistemas automatizados de corda vibrante em 2018. O documento aponta que variações irregulares de pressão, seguidas de falhas de registro em alguns sensores, foram observadas nos meses anteriores ao rompimento. Em diversos pontos, leituras abruptamente elevadas não foram correlacionadas com chuvas ou variações de nível no reservatório, o que reforça a importância de um sistema de aquisição confiável e de alertas automáticos para a detecção precoce de anomalias.

Para cada instrumento, a medição de pressão neutra deve ser acompanhada de verificação da tendência temporal. A análise de séries históricas é essencial para identificar padrões sazonais e desvios. Silva e Garcia (2025) enfatizam que a detecção de anomalias em

dados de piezômetros não deve se basear apenas em limites absolutos, mas em desvios contextuais, por exemplo, uma elevação repentina de pressão em período de estiagem pode indicar infiltração anômala ou falha de drenagem.

Greenhills Operations (2021) apresenta um exemplo prático de operação bem-sucedida de um sistema de instrumentação em barragens de rejeito. Os piezômetros elétricos instalados nos taludes de montante e jusante transmitiam dados horários via rádio, integrando-se a um banco central. Durante o ciclo de operação 2020–2021, nenhum aumento anormal de pressão foi identificado, e o gradiente hidráulico máximo calculado manteve-se em torno de $i = 0,35$, valor seguro em relação ao gradiente crítico dos materiais empregados. O relatório destaca que a correlação entre leituras de piezômetros e medidores de vazão nos drenos permitiu calibrar modelos de percolação e aprimorar o sistema de alerta.

No Brasil, Andrade *et al.* (2018) desenvolveram o projeto iWater, voltado ao monitoramento automatizado da Barragem Santa Bárbara, no Rio Grande do Sul. A proposta utiliza tecnologia LoRaWAN para transmitir dados de sensores de nível e piezômetros distribuídos em áreas de difícil acesso. O sistema opera com baixo consumo energético e permite o acompanhamento remoto em tempo real. Essa iniciativa representa um avanço na digitalização da instrumentação geotécnica nacional.

O avanço tecnológico também tem permitido a integração de sensores piezométricos com IoT e sistemas ciberfísicos. Souza *et al.* (2023) desenvolveram um protótipo para alerta de deslizamentos com sensores IoT baseados em microcontroladores ESP32, demonstrando a viabilidade de comunicação contínua entre dispositivos autônomos e plataformas na nuvem. Aplicações semelhantes podem ser adaptadas ao monitoramento piezométrico de barragens, garantindo a transmissão segura de dados a longas distâncias e a operação em locais sem rede elétrica.

Outra prática importante é a correlação cruzada entre instrumentos, conforme descrito por Silva, Caetano e Pierozan (2024). O estudo mostrou que a análise de regressão linear entre pares de piezômetros permite detectar falhas de sensores. Por exemplo, se dois instrumentos situados em uma mesma zona hidráulica apresentam comportamento linear e um deles subitamente se desvia da tendência, há alta probabilidade de erro de medição. Essa técnica é fundamental em sistemas automatizados que geram milhares de leituras diárias.

A instrumentação moderna também tem se beneficiado da integração entre modelagem numérica e dados de campo. Em projetos recentes, modelos de fluxo gerados no SEEP/W são continuamente ajustados com base em dados piezométricos reais, permitindo a atualização automática das superfícies de fluxo e das zonas de risco. Esse processo, conhecido como

calibração dinâmica, é uma tendência em sistemas de monitoramento inteligente de barragens (Ribeiro, 2023).

Por fim, Silva e Garcia (2025) e Souza *et al.* (2023) apontam que o avanço da instrumentação rumo à automação total só será eficaz se acompanhado por interpretação inteligente dos dados. O volume de medições geradas por piezômetros elétricos exige algoritmos capazes de filtrar ruídos, identificar tendências e emitir alertas de forma autônoma. Assim, a piezometria automatizada, integrada a tecnologias de comunicação IoT e a modelos de machine learning, consolida-se como a base dos sistemas modernos de monitoramento preditivo de barragens.

2.6 Níveis de controle e segurança de barragens

A segurança de barragens depende do monitoramento sistemático de parâmetros físicos e hidráulicos capazes de indicar alterações no comportamento da estrutura. No Brasil, essa atividade é regulamentada pela Política Nacional de Segurança de Barragens (PNSB), instituída pela Lei nº 12.334/2010, que estabelece diretrizes para o projeto, operação, inspeção e desativação de barragens destinadas à acumulação de água, rejeitos ou resíduos industriais. Segundo a PNSB, cada barragem deve dispor de um Plano de Segurança de Barragem (PSB), contendo a caracterização da estrutura, histórico de inspeções e o conjunto de instrumentos necessários ao acompanhamento do desempenho (Brasil, 2010).

Nesse contexto, a adoção de níveis de controle representa uma ferramenta essencial para o gerenciamento de riscos. Conforme Bragioni (2022), os níveis de controle são faixas de referência associadas às leituras de instrumentação geotécnica, especialmente piezômetros e medidores de recalque, que servem para definir quando a condição de operação passa de estável para anômala. Assim, eles funcionam como gatilhos de decisão: quando um parâmetro ultrapassa determinado limite, ações preventivas e corretivas devem ser imediatamente executadas.

A definição desses níveis depende da relação entre pressão neutra (u) e o fator de segurança (FS) obtido nas análises de estabilidade. Essa correlação é determinada a partir de modelagem numérica ou retroanálises com base em dados históricos. Em termos gerais, Ribeiro (2023) propõe a classificação apresentada na Tabela 1:

Tabela 1 - Níveis de controle de gerenciamento de risco

Faixa de Controle	Condição	Fator de segurança (FS)
Normal	Estável	$FS \geq 1,5$
Atenção	Redução pontual da segurança	$1,5 > FS \geq 1,3$
Alerta	Condição de risco iminente	$1,3 > FS \geq 1,1$
Emergência	Instabilidade provável	$FS < 1,1$

Fonte: Adaptado de Ribeiro (2023)

Essas faixas permitem associar leituras de piezômetros a estados de estabilidade do maciço. Por exemplo, se um piezômetro indicar aumento de 2,5 m no nível freático e a simulação numérica correlacionar esse acréscimo a uma redução do FS de 1,5 para 1,3, o instrumento deverá emitir sinal de atenção.

Segundo Bragioni (2022) e Ribeiro (2023), o processo de definição de níveis de controle envolve três etapas principais: (1) construção do modelo geotécnico e hidráulico da barragem; (2) calibração com dados piezométricos históricos; e (3) simulação de cenários de instabilidade para estabelecer as faixas limite. Essa metodologia foi aplicada por Ribeiro (2023) em uma barragem de rejeitos simulada no software Slide2, utilizando análises determinísticas de fluxo e estabilidade.

Robertson *et al.*, (2019), fornece um exemplo oposto — um caso em que a inexistência de níveis de controle efetivos e a ausência de resposta a leituras anômalas contribuíram para a falha estrutural. O documento mostra que vários piezômetros registraram leituras inconsistentes, sem correlação entre instrumentos próximos, e mesmo assim não houve disparo de alerta nem bloqueio operacional. A ausência de um sistema automatizado de comparação entre dados contribuiu para a perda de confiabilidade da instrumentação.

Em contrapartida, o relatório Greenhills Operations (2021) demonstra uma prática bem-sucedida. A barragem canadense utiliza um Trigger Action Response Plan (TARP) plano que define ações graduais de resposta conforme o nível de risco. Por exemplo, um aumento de 20 % na carga piezométrica média gera a categoria “Level 2”, exigindo inspeção imediata de campo. A partir de 40 %, o evento é classificado como “Level 3”, com acionamento de procedimentos de emergência. Essa metodologia, equivalente aos níveis de controle brasileiros, assegura rastreabilidade e resposta estruturada.

Além das análises estáticas, Silva, Caetano e Pierozan (2024) demonstraram que a correlação estatística entre piezômetros pode servir como ferramenta adicional para a validação dos níveis de controle.

O uso de IoT e telemetria tem se mostrado uma aliada na manutenção dos níveis de controle em tempo real. Andrade *et al.* (2018), por meio do projeto iWater, demonstraram que sensores piezométricos integrados à rede LoRaWAN permitem medições automatizadas e comunicação contínua em barragens de grande porte. Essa tecnologia garante o envio de alertas instantâneos ao sistema central sempre que um valor ultrapassa o limite programado, reduzindo o tempo de resposta e eliminando a dependência de inspeções manuais.

No campo da automação, Souza *et al.* (2023) introduzem o conceito de planos de resposta automatizados em sistemas ciberfísicos. Nesses sistemas, as leituras dos sensores são processadas por algoritmos de inteligência artificial que classificam os eventos em tempo real. Quando uma condição de risco é detectada, o sistema aciona automaticamente protocolos de inspeção, envia notificações a engenheiros responsáveis e atualiza dashboards operacionais. Essa abordagem integra o conceito dos níveis de controle ao de resposta inteligente, criando uma estrutura de monitoramento contínuo e adaptativo.

A aplicação de inteligência artificial na definição e ajuste dinâmico dos níveis de controle também vem sendo estudada. Silva e Garcia (2025) propõem o uso de algoritmos de detecção de anomalias como LOF para recalibrar automaticamente os limites de atenção e alerta com base na evolução histórica dos dados. Assim, os níveis deixam de ser estáticos e passam a se ajustar conforme o comportamento real da barragem, aumentando a precisão dos alertas e reduzindo falsos positivos.

Além das abordagens numéricas e automatizadas, é essencial que os níveis de controle estejam integrados aos Planos de Ação de Emergência (PAE), conforme preconiza a PNSB. O PAE define o conjunto de medidas a serem adotadas em caso de detecção de anomalia desde o isolamento da área e acionamento de sirenes até a comunicação com a Defesa Civil. Conforme Gacu *et al.* (2025), a integração entre dados hidrológicos, piezométricos e meteorológicos em uma plataforma única é crucial para antecipar riscos e coordenar respostas de forma eficaz.

Por fim, a literatura e os relatórios técnicos analisados convergem em um ponto: a eficácia dos níveis de controle depende não apenas da instrumentação e da modelagem, mas principalmente da interpretação e da resposta operacional. A combinação entre medições confiáveis, modelos calibrados e sistemas automatizados de alerta constitui a base da segurança moderna de barragens, alinhando as exigências normativas da PNSB às melhores práticas internacionais de engenharia geotécnica e gestão de riscos.

2.7 Monitoramento inteligente de barragens: integração IoT e inteligência artificial

O avanço tecnológico recente tem transformado a engenharia geotécnica, permitindo a transição de métodos de monitoramento manuais e intermitentes para sistemas contínuos e inteligentes. Essa evolução baseia-se na convergência entre a Internet das Coisas (IoT), responsável pela aquisição e transmissão de dados, e a Inteligência Artificial (IA), que viabiliza a interpretação automatizada dessas informações.

2.7.1 Arquitetura IoT para monitoramento geotécnico

A IoT baseia-se na interconexão de dispositivos físicos equipados com sensores e capacidade de comunicação em rede, permitindo a coleta, transmissão e análise de dados em tempo real (Yaqoob *et al.*, 2017). No contexto de barragens, a IoT possibilita o desenvolvimento de sistemas de monitoramento contínuo, remoto e autônomo, reduzindo a dependência de inspeções presenciais e ampliando a confiabilidade das informações.

Segundo Ghosh, Edwards e Hosseini (2020) e Xie (2021), as arquiteturas IoT modernas são divididas em três camadas fundamentais: a camada de percepção (aquisição de dados via sensores como piezômetros), a camada de rede (transmissão via tecnologias sem fio) e a camada de aplicação (processamento e análise de dados).

Para superar as limitações de alcance e consumo energético em grandes áreas, tecnologias como a LoRaWAN têm se destacado. O trabalho de Andrade *et al.* (2018), com o projeto *iWater*, demonstrou a eficácia dessa tecnologia no monitoramento da Barragem Santa Bárbara (RS), permitindo a transmissão de dados em tempo real com estabilidade mesmo em condições climáticas adversas. A LoRaWAN opera na faixa sub-GHz com alta sensibilidade de recepção, permitindo coberturas de até 15 km em áreas abertas e baixo consumo energético, o que viabiliza o uso de baterias de longa duração (Xie, 2021; Umesha *et al.*, 2021).

Além da transmissão, a IoT amplia a capacidade de integração. A Revista Minérios & Minerales (2025) destaca que plataformas IoT integram piezômetros, inclinômetros e pluviômetros em uma base central na nuvem. Essa abordagem possibilita o monitoramento distribuído, onde diversos nós sensores cooperam para formar uma malha de observação contínua, reduzindo a vulnerabilidade a falhas isoladas (Gacu *et al.*, 2025).

A interoperabilidade entre esses dispositivos é garantida pelo uso de padrões abertos. Protocolos como o MQTT (*Message Queuing Telemetry Transport*) são ideais para conexões de baixa largura de banda (Hildebrandt; Snook, 2023), enquanto formatos de dados como JSON e YAML facilitam o intercâmbio e a leitura de configurações por sistemas em Python (Ecma International, 2017; Ben-Kiki; Evans; D'Anjou, 2021; Lutz, 2013). Umesha *et al.*

(2021) apontam ainda que sensores IoT de baixo custo podem reduzir significativamente o orçamento de monitoramento, mantendo a precisão adequada para aplicações geotécnicas.

2.7.2 Inteligência Artificial e Machine Learning

Enquanto a IoT resolve o desafio da coleta, a Inteligência Artificial (IA) emerge como recurso essencial para processar grandes volumes de dados (*Big Data*). Conforme EBO Geotech (2025), a IA automatiza a avaliação de medições em tempo real, detectando desvios que sinalizam riscos de colapso.

Os modelos de *Machine Learning* podem ser divididos em duas abordagens: supervisionada e não supervisionada (Umesha *et al.*, 2021).

- **Abordagem supervisionada:** o modelo aprende a distinguir comportamentos normais e anômalos com base em dados rotulados. Barros (2020) utilizou RNA para prever a ocorrência de *piping*, alcançando acurácia superior a 90% a partir de parâmetros geotécnicos.
- **Abordagem não supervisionada:** preferível quando não há histórico suficiente de falhas. O modelo identifica padrões ocultos sem rótulos prévios (Barros, 2020).

A integração entre IA e IoT permite também a "inteligência de borda" (*Edge AI*), onde dados são processados diretamente em microcontroladores (como o ESP32), permitindo a geração de alertas locais imediatos (Souza *et al.*, 2023; Andrade *et al.*, 2018).

2.7.3 Detecção de anomalias

A detecção de anomalias consiste em identificar valores que divergem significativamente do padrão normal de operação, como falhas de sensores ou início de *piping* (Silva; Garcia, 2025). Para isso, algoritmos específicos têm se mostrado superiores a limites fixos.

- **LOF:** Silva e Garcia (2025) aplicaram este algoritmo baseado em densidade para detectar anomalias em piezômetros, obtendo F1-Score de 0,868 e precisão de 100%. O método avalia o grau de isolamento de uma amostra em relação aos seus vizinhos, sendo eficaz na distinção entre anomalias reais e ruídos.
- **Autoencoders:** Irazábal *et al.* (2025) utilizaram autoencoders (redes neurais profundas) para reconstruir o padrão normal dos dados. Quando o erro de reconstrução é elevado, o evento é classificado como anômalo, técnica que reduziu em 98% as leituras falsas em seus estudos.

- **Redes LSTM:** para séries temporais contínuas, as redes *Long Short-Term Memory* (LSTM) são capazes de armazenar dependências de longo prazo, prevendo valores futuros de pressão neutra e vazão (Souza *et al.*, 2023; Ruma *et al.*, 2023).

A validação desses modelos utiliza métricas como Precisão, Revocação e F1-Score (Silva; Garcia, 2022), além de correlação cruzada entre sensores para confirmar se um alerta é estrutural ou falha de instrumento (Silva; Caetano; Pierozan, 2024).

Conclui-se, conforme Silva e Garcia (2025) e Gacu *et al.* (2025), que a convergência entre IA, IoT e modelagem geotécnica permite que o monitoramento deixe de ser reativo para se tornar preditivo e autônomo, constituindo um novo paradigma para a segurança de barragens.

3 METODOLOGIA

O presente capítulo detalha o percurso metodológico adotado para o desenvolvimento do sistema autônomo de monitoramento em barragens proposto neste trabalho. A fim de atingir os objetivos estabelecidos, a metodologia foi estruturada de maneira a integrar a fundamentação teórica sobre segurança de barragens e o fenômeno de *piping* com a implementação prática de modelos computacionais.

A abordagem descreve desde a classificação da pesquisa até a construção do ambiente de simulação, passando pelo processamento dos dados piezométricos e a aplicação dos algoritmos de Inteligência Artificial (Autoencoder e LOF). Por fim, são apresentados os critérios utilizados para a avaliação de desempenho do sistema e as ferramentas computacionais que deram suporte ao desenvolvimento da solução.

3.1 Tipo de Pesquisa

No que concerne à sua natureza, a pesquisa classifica-se como aplicada. O trabalho não se limita à revisão de conceitos, mas propõe a construção de uma solução tecnológica: um ambiente computacional capaz de processar dados de instrumentação geotécnica e identificar padrões de risco em tempo real. A aplicação prática se materializa no desenvolvimento de algoritmos que utilizam bibliotecas como Scikit-learn, Pytorch e Pandas para resolver um problema da engenharia de barragens, a detecção precoce de erosão interna (*piping*) antes que ocorra a ruptura do maciço.

Quanto aos objetivos, a pesquisa classifica-se como exploratória. O estudo investiga a aplicabilidade de algoritmos de aprendizado de máquina não supervisionado, especificamente LOF e Autoencoders, na análise de dados piezométricos.

3.2 Procedimentos metodológicos

O desenvolvimento do trabalho foi estruturado em etapas sequenciais, abrangendo desde a fundamentação teórica até a implementação e validação dos modelos computacionais. As etapas são descritas a seguir.

3.2.1 Levantamento teórico

A etapa inicial consistiu no aprofundamento teórico sobre os temas que compõem a base do sistema proposto. A revisão abordou a mecânica dos solos e a segurança de barragens, especificamente a compreensão física do fenômeno de *piping* e os métodos de monitoramento piezométrico. Simultaneamente, estudou-se a aplicação da linguagem Python, bem como o uso de bibliotecas específicas para análise de dados. A pesquisa integrou ainda conceitos de


Internet das Coisas (IoT) e algoritmos de Inteligência Artificial, fundamentando-se em normas técnicas, artigos recentes e na documentação das ferramentas utilizadas.

3.2.2 Definição dos parâmetros e variáveis

Nesta etapa, foram estabelecidas as grandezas que compõem o modelo digital da barragem, estruturadas em três categorias: parâmetros físicos e geométricos, sinais de entrada simulados e variáveis derivadas (*features*).

Parâmetros físicos e geométricos para representar a estrutura monitorada, definiram-se as propriedades estáticas que regem o comportamento físico e os cálculos de segurança. A geometria da barragem foi configurada com altura de 60,0 m, largura da crista de 12,0 m, taludes de 3,0 (montante) e 2,5 (jusante) conforme a Figura 5. O sistema de instrumentação foi posicionado com 5 piezômetros instalados nas profundidades de 5,0 m, 10,0 m, 15,0 m, 20,0 m e 25,0 m.

Figura 5 - Geometria da barragem



Fonte: Autor (2025)

Os parâmetros do solo, essenciais para o cálculo de gradientes críticos e tempos de fluxo, foram definidos como (Lima Neto, 2025):

- Peso específico saturado (γ_{sat}): 19,62 kN/m³;
- Índice de vazios (e): 0,58;
- Grau de saturação (S): 81%;
- Condutividade hidráulica (k): $2,41 \times 10^{-7}$ m/s.

Adicionalmente, estabeleceu-se uma carga hidráulica de referência a montante (*head difference*) de 100,0 m para subsidiar os cálculos de gradiente hidráulico.

Para simular a dinâmica temporal das pressões nos piezômetros, utilizou-se uma estrutura de modelos Auto-Regressivos com Entradas Exógenas (ARX). Conforme fundamentado por Aguirre (2015), essa abordagem permite descrever a pressão atual do sistema como uma combinação linear de seus estados passados (memória do solo) e das forças externas atuantes. O simulador desenvolvido gera as séries temporais conforme a Equação 6.

$$P(t) = P_{base} + \sum \alpha_k * (P(t-k) - P_{base}) + \beta_c * C(t-d) + \beta_m * M^*(t) + \varepsilon(t) \quad (6)$$

Onde:

- $P(t)$ é a pressão piezométrica no instante t ;
- α_k são os coeficientes auto-regressivos que representam a inércia hidráulica do maciço;
- $C(t-d)$ é a precipitação pluviométrica com um atraso (*delay*) d , simulando o tempo de infiltração;
- $M(t)$ é o nível do reservatório ajustado pela permeabilidade;
- $\varepsilon(t)$ representa o ruído branco do sensor.

A incorporação das variáveis exógenas (chuva e nível) com defasagem temporal segue as diretrizes para sistemas de monitoramento automatizado de barragens estabelecidas pela ICOLD (2000), garantindo que o modelo capture a resposta hidrodinâmica realista da estrutura. Para potencializar a detecção de anomalias, o conjunto de dados brutos foi enriquecido com variáveis derivadas (*features*). Os indicadores de segurança foram calculados com base nos princípios de mecânica dos solos descritos por Craig (2012). O algoritmo implementado no módulo de extração de características calcula:

- Gradiente Hidráulico (i): a perda de carga por unidade de comprimento de percolação;
- Gradiente Crítico (i_{crit}): o limite teórico onde a força de percolação anula o peso efetivo do solo, calculado em função do peso específico saturado (γ_{sat}) e da densidade da água (γ_w);
- Fator de Segurança contra Piping (FS): definido pela razão entre o gradiente crítico e o gradiente atuante ($FS = i_{crit} / i$), fundamental para avaliar a estabilidade interna da barragem.

Além das métricas físicas, foram extraídas estatísticas de correlação cruzada (cross-correlation) para monitorar a consistência entre as leituras dos sensores e as variações ambientais.

Para garantir a consistência entre o treinamento e a inferência em tempo real, definiu-se um espaço de *features* fixo, submetido a processos de normalização via *scaler* padronizado.

3.2.3 Desenvolvimento do ambiente computacional

A implementação do sistema foi realizada utilizando a linguagem Python 3.9, escolhida pela robustez do seu ecossistema voltado à ciência de dados e engenharia. O ambiente foi estruturado para garantir a integração fluida entre a simulação física, o treinamento dos modelos de Inteligência Artificial e a operação de monitoramento em tempo real.

Para atender aos requisitos de desempenho e complexidade matemática, selecionou-se um conjunto específico de bibliotecas:

- Simulação e pré-processamento: utilizaram-se NumPy e SciPy para a execução dos cálculos vetoriais do modelo ARX e para as rotinas de processamento de sinais.
- Modelagem inteligente: a construção do ensemble combinou o PyTorch, utilizado na implementação do Autoencoder baseado em arquitetura Transformer para aprendizado de representações latentes, e o LightGBM, empregado para a classificação supervisionada de alta eficiência baseada em árvores de decisão (*Gradient Boosting*).
- Visualização: a biblioteca Matplotlib foi utilizada para a geração de gráficos padronizados, permitindo a análise visual das séries temporais, curvas de aprendizado e diagnósticos de detecção.

O software foi organizado em módulos independentes para assegurar a separação de responsabilidades e a manutenibilidade do código:

- Simulação (*data_utils*): módulo responsável pela geração dos dados sintéticos e injeção controlada de anomalias;
- Engenharia de features (*feature_utils*): responsável pela extração de atributos estatísticos e temporais das janelas de leitura;
- Treinamento (*ensemble_pipeline*): gerencia o ciclo de vida dos modelos, desde a separação dos dados até a calibração dos limiares de decisão;
- Monitoramento (*monitor_ensemble*): módulo de inferência que carrega os artefatos treinados e executa a detecção em fluxo contínuo.

Todos os artefatos gerados durante o treinamento - incluindo os modelos binários, o scaler para normalização e os arquivos de limiares (*thresholds*) - são versionados e persistidos no diretório `models/`, garantindo que o módulo de monitoramento utilize exatamente os mesmos parâmetros validados na etapa de treino.

Para assegurar a reprodutibilidade dos experimentos, todos os hiperparâmetros (físicos, geométricos e algorítmicos) foram centralizados em um arquivo único de configuração (*config.yaml*). O sistema opera com sementes aleatórias (*seeds*) fixas e utiliza um conjunto de dados de validação estático (*replay buffer*) para garantir que os resultados e gráficos apresentados sejam consistentes e auditáveis, eliminando variações estocásticas entre execuções distintas.

A operação do sistema é realizada pelo script *monitor_ensemble.py*, que simula a leitura de sensores em tempo real e aplica o conjunto de modelos treinados para classificar cada janela temporal. A validação do sistema ocorre de forma offline nos conjuntos de teste, onde são calculadas métricas como curvas ROC/PR e matrizes de confusão, com relatórios salvos automaticamente no diretório `reports/`.

3.2.4 Simulação da barragem

A geração dos dados sintéticos necessários para o treinamento e validação do sistema foi operacionalizada pela função *prepare_data* do módulo *data_utils*. O núcleo da simulação baseia-se em um modelo ARX (Auto-Regressivo com Entradas Exógenas), capaz de produzir séries temporais diárias que correlacionam as leituras dos piezômetros com as variáveis exógenas (chuva e nível de montante), incorporando componentes estocásticos de ruído para mimetizar a variabilidade real dos sensores.

O comportamento da simulação foi delimitado pelos parâmetros físicos definidos no arquivo de configuração (*config.yaml*). O modelo incorpora propriedades do solo como o peso específico saturado (γ_{sat}), o índice de vazios, o grau de saturação (S_r) e a condutividade hidráulica (k). Além disso, a simulação considera a geometria da barragem através da diferença de carga hidráulica entre montante e fundação (*head_difference_m*) e aplica fatores de atenuação baseados na profundidade de cada sensor para reproduzir fielmente os processos de percolação e os tempos de atraso (*lag*) na resposta da poropressão.

Para enriquecer a capacidade de detecção do sistema, a simulação calcula continuamente o contexto hidráulico (*hydraulic_context*). Esse processo envolve o armazenamento de janelas temporais de longo prazo (*buffers*) das séries de chuva e nível de montante. A partir desses dados, são derivadas métricas de segurança críticas, como a razão de carga (*head ratio*), o gradiente hidráulico atual (i), o gradiente crítico (i_{crit}) e o Fator de

Segurança contra piping (*FS_piping*). Essas variáveis compõem a entrada para os algoritmos de detecção, fornecendo uma visão física do estado da barragem além da pura estatística dos dados.

A robustez do modelo foi assegurada através de técnicas de Monte Carlo e bootstrapping. O sistema foi configurado para introduzir variabilidade controlada (*jitter*) nos parâmetros hidráulicos e utilizar sementes aleatórias variáveis (*seed_base*), permitindo a execução de múltiplas rodadas de simulação. Essa abordagem gera dispersão nas métricas de desempenho, garantindo que o ensemble seja validado sob diferentes condições operacionais e não apenas em um cenário determinístico único.

Para a validação final e a geração de gráficos padronizados, estabeleceu-se um mecanismo de Replay Rotulado. Um conjunto de dados fixo, contendo as leituras dos sensores, as variáveis exógenas e os rótulos reais de anomalia (*ground truth*), é salvo no arquivo `reports/replay_val_with_labels.npz`. O uso deste arquivo permite reexecutar o monitor e avaliar a eficácia dos limiares (*thresholds*) em um ambiente controlado, sem a necessidade de regenerar dados aleatórios a cada teste.

O objetivo central desta etapa foi aproximar a resposta hidrodinâmica simulada da realidade física (respeitando a física da percolação e os atrasos por profundidade) ao mesmo tempo em que se preserva o contraste estatístico necessário entre o comportamento normal e as anomalias de *piping*. Isso viabilizou o treinamento eficaz do ensemble e a definição de limiares de alerta precisos.

3.2.5 Processamento dos dados

A etapa de processamento foi responsável por transformar as séries temporais brutas geradas pela simulação em vetores de características estruturados, adequados para o treinamento dos modelos de Inteligência Artificial. Este fluxo foi implementado de forma modular para garantir a integridade dos dados entre as fases de treinamento e monitoramento.

A ingestão dos dados é gerenciada pela função *prepare_data* do módulo *data_utils*. Nesta fase, as séries contínuas dos sensores (piezômetros), chuva e nível de montante são segmentados em janelas deslizantes de comprimento fixo (*seq_length*), configurado para capturar a dinâmica recente do sistema. Além da janela principal, o sistema estrutura buffers de longo prazo (*long_window_days* e *daily_buffer*) para permitir a análise de tendências históricas. Para garantir a reprodutibilidade e a consistência da validação, os dados processados são serializados em arquivos. npz rotulados, contendo as matrizes de sensores e suas respectivas variáveis exógenas.

O tratamento dos dados incluiu a verificação de valores faltantes e a mitigação de ruídos espúrios. A normalização foi realizada utilizando a técnica de *StandardScaler* (padronização por média zero e desvio padrão unitário). Um aspecto metodológico crítico foi o ajuste (*fit*) do *scaler* exclusivamente sobre as séries normais de treinamento. Essa estratégia preserva as características estatísticas das anomalias nos conjuntos de teste e validação, mantendo o contraste necessário para que os algoritmos de detecção identifiquem os desvios de comportamento (*outliers*).

A extração de padrões foi realizada pelos módulos *feature_utils.py* e *ensemble_pipeline*. Ao invés de alimentar os modelos apenas com dados brutos, calculou-se um conjunto denso de variáveis derivadas (*features*), incluindo:

- Estatísticas multijanela: média, desvio padrão e percentis calculados em diferentes horizontes temporais;
- Dinâmica temporal: inclinação (*slopes*), variações delta e taxas de cruzamento por zero;
- Correlações físicas: correlação cruzada inter-sensores e correlação defasada entre as variáveis exógenas (chuva/nível) e a resposta piezométrica;
- Indicadores hidráulicos: cálculo direto de métricas de segurança como razão de carga (*head ratio*), gradiente hidráulico e Fator de Segurança contra piping (*FS_piping*);
- Vetores latentes: representações compactas extraídas das camadas internas do Autoencoder.

Para assegurar que o módulo de monitoramento em tempo real receba os dados na ordem correta, a lista de atributos é padronizada e salva no arquivo *feature_names.json*.

Os dados foram segregados em conjuntos de treinamento, validação e teste, garantindo o balanceamento de classes através da geração controlada de cenários sintéticos. Os rótulos (labels) foram definidos binariamente: 0 para operação normal e 1 para eventos de piping. O processo incluiu a opção de bootstrap para aumentar a robustez estatística dos conjuntos de validação.

A definição dos limiares de decisão (*thresholds*) não foi arbitrária, mas calculada estatisticamente sobre os escores de anomalia gerados pelos modelos (VAE, LOF e o score combinado *ensemble_f2*). O processo de calibração utilizou métricas alvo, como o F-Beta e taxas de falsos positivos (FPR) aceitáveis, para determinar os cortes ótimos. Esses valores

são armazenados no arquivo *thresholds.json*, sendo utilizados tanto pelo monitor em tempo real quanto para a geração dos gráficos de desempenho.

3.2.6 Aplicação dos algoritmos de detecção de anomalias

A estratégia de detecção adotada baseou-se em um ensemble heterogêneo, projetado para mitigar as limitações individuais de cada algoritmo e aumentar a robustez do diagnóstico. O sistema combina três abordagens distintas de aprendizado de máquina, cujas saídas são fundidas para gerar um escore de anomalia unificado.

O núcleo de detecção é composto pelos seguintes modelos:

- **Autoencoder Variacional (Transformer VAE):** uma rede neural profunda baseada em mecanismos de atenção (*Self-Attention*), treinada para reconstruir os padrões normais das séries temporais. O erro de reconstrução serve como indicador primário de anomalia: quanto maior a divergência entre a entrada e a saída, maior a probabilidade de falha.
- **LOF:** um algoritmo baseado em densidade que identifica pontos isolados no espaço de características (*features*). Ele complementa o autoencoder ao detectar anomalias locais que podem não gerar altos erros de reconstrução global, mas que violam a topologia esperada dos dados vizinhos.
- **LightGBM Classifier:** um modelo supervisionado de *Gradient Boosting* que atua como classificador final. Ele recebe como entrada as *features* originais, os erros de reconstrução do VAE e os escores do LOF, refinando a decisão para distinguir entre anomalias reais de piping e ruídos complexos.

Para garantir a consistência da inferência, o vetor de entrada segue uma estrutura definida no arquivo *feature_names.json*. Antes de serem processados pelos modelos, os dados são normalizados por um scaler treinado exclusivamente em dados normais, assegurando que as anomalias mantenham suas magnitudes estatísticas distorcidas durante a análise. A função *detect_anomaly_ensemble* coordena a execução sequencial dos três modelos e a fusão dos seus resultados.

No módulo de monitoramento, implementou-se um mecanismo de Limiares Adaptativos (*AdaptiveThresholdAdapter*). Esse componente ajusta dinamicamente o ponto de corte com base no histórico recente de pontuações, permitindo que o sistema se acomode a lentas variações sazonais ou operacionais sem disparar alarmes falsos contínuos, mantendo a sensibilidade a desvios abruptos.

Para cada janela temporal processada, o sistema fornece um conjunto completo de diagnósticos: o escore de anomalia final, a decisão binária (Normal/Anômalo), o nível de confiabilidade da predição e o rótulo da classe provável. Essas métricas são agregadas para gerar relatórios de desempenho (Curvas ROC/PR e Matriz de Confusão) utilizando o mecanismo de replay rotulado, validando a eficácia do modelo antes de sua implantação.

3.2.7 Avaliação de desempenho

A eficácia do sistema proposto foi mensurada por meio de métricas quantitativas e análises gráficas, aplicadas sobre os conjuntos de validação e teste. A avaliação priorizou a capacidade do modelo em identificar anomalias (sensibilidade), considerando as implicações de segurança associadas à não detecção de falhas em estruturas de barragem e terra.

Para a classificação binária (Normal vs. Piping), foram calculadas as métricas de Precisão (Precision), Revocação (Recall) e a Medida-F (F-Measure). O estudo adotou o $F\beta$ -Score com $\beta = 2$ (F2) como métrica de referência para a otimização, como pode ser localizado na Equação 7. O F2 atribui maior peso à Revocação em comparação à Precisão, favorecendo a detecção de eventos positivos (anomalias), ainda que isso possa resultar em maior número de falsos alarmes. A separabilidade entre as classes foi avaliada pelas áreas sob as curvas ROC (AUC-ROC) e Precisão-Revocação (AUC-PR).

$$F\beta = (1 + \beta^2) \cdot (\text{Precisão} \cdot \text{Recall}) / ((\beta^2 \cdot \text{Precisão}) + \text{Recall}) \quad (7)$$

O limiar de decisão (*cut-off*) foi definido estatisticamente. O sistema avaliou critérios baseados na maximização do $F\beta$, em Taxas de Falsos Positivos (FPR) alvo e em percentis da distribuição dos escores (P95 e P99). Os valores obtidos foram armazenados no arquivo `thresholds.json`, permitindo a análise comparativa entre o uso de limiares fixos e o sistema de limiares adaptativos implementado no monitoramento.

A análise dos resultados utilizou Matrizes de Confusão para quantificar Verdadeiros Positivos (VP), Falsos Negativos (FN) e Falsos Positivos (FP). Para investigar o comportamento do modelo em cenários específicos, utilizou-se o arquivo de replay rotulado (`replay_val_with_labels.npz`), o que permitiu correlacionar os erros de classificação com os tipos de anomalia simulados (ex: piping sutil ou intermitente).


A validação incluiu a geração de curvas ROC e PR, histogramas de distribuição de escores por classe e gráficos de séries temporais comparando a evolução do escore de anomalia em relação ao limiar. Para avaliar a estabilidade dos resultados, aplicou-se o método de Monte Carlo, reportando as médias, desvios-padrão e intervalos de confiança (IC 95%) das métricas obtidas em múltiplas rodadas de simulação com variabilidade de parâmetros (*jitter*) e bootstrapping.

A consistência entre o treinamento e os resultados apresentados foi assegurada pelo compartilhamento dos arquivos de configuração (*feature_names.json* e *thresholds.json*) e dos dados de validação, garantindo que as métricas reportadas reflitam o desempenho do modelo final.

3.2.8 Fluxograma metodológico

A fim de sintetizar a abordagem desenvolvida e permitir uma visualização sistêmica de todo o processo de pesquisa, elaborou-se o fluxograma metodológico apresentado na Figura 6. O diagrama organiza as atividades em quatro fases sequenciais e interdependentes:

Figura 6 - Fluxograma metodológico



Fonte: Autor (2025)

- **Levantamento teórico, definição dos parâmetros e variáveis:** etapa inicial onde foram estabelecidos os parâmetros geotécnicos da barragem (geometria e propriedades do solo) e realizada a revisão bibliográfica que sustentou as escolhas tecnológicas;
- **Simulação e geração de dados:** fase responsável pela criação do ambiente computacional e execução do modelo ARX, gerando as séries temporais sintéticas que representam tanto o comportamento normal quanto os cenários de falha por *piping*;
- **Processamento de dados e o algoritmo de detecção de anomalias:** etapa central onde os dados brutos foram transformados através da engenharia de *features* e submetidos ao *ensemble* de detecção, composto pelos modelos *Transformer VAE*, *LOF* e o classificador supervisionado *LightGBM*;
- **Validação de desempenho:** fase final dedicada à calibração dos limiares de decisão (focada no F2-Score) e à verificação da robustez do sistema por meio de simulações de Monte Carlo e métricas de desempenho (curvas ROC e PR).

Essa estruturação garantiu que o desenvolvimento do sistema seguisse um fluxo lógico, desde a compreensão física do fenômeno até a validação estatística do modelo de inteligência artificial proposto.

3.3 Ferramentas utilizadas

O desenvolvimento do sistema computacional foi realizado utilizando a IDE (Integrated Development Environment) Visual Studio Code (VSCode). A escolha desta ferramenta deve-se à sua flexibilidade na organização de módulos e facilidade de depuração (*debugging*). O processo de codificação foi auxiliado por ferramentas baseadas na tecnologia OpenAI Codex, uma extensão que utiliza inteligência artificial para interpretar a intenção do desenvolvedor em linguagem natural e sugerir blocos de código sintaticamente corretos, acelerando a prototipagem e a implementação de funções complexas.

A linguagem base adotada foi o Python, suportada por um ecossistema de bibliotecas especializadas que permitiram a implementação do pipeline completo, desde a simulação até o monitoramento:

- **NumPy, Pandas e SciPy:** utilizadas para a manipulação vetorial de alta performance, estruturação das séries temporais em janelas deslizantes e implementação das funções matemáticas do modelo ARX de simulação;
- **PyTorch:** framework de Deep Learning empregado na construção e treinamento da rede neural Transformer Autoencoder, permitindo o uso de mecanismos de atenção para capturar dependências temporais;
- **LightGBM:** biblioteca de Gradient Boosting utilizada para implementar o classificador supervisionado do ensemble, escolhida por sua eficiência computacional e alta precisão em dados estruturados;
- **Scikit-learn:** responsável pelas rotinas de pré-processamento (normalização via StandardScaler), implementação do algoritmo LOF (Local Outlier Factor) e cálculo das métricas de validação e seleção de modelos;
- **Matplotlib:** ferramenta de visualização utilizada para a geração de gráficos estáticos padronizados, incluindo curvas de aprendizado, séries temporais dos piezômetros e curvas de desempenho (ROC/PR);
- **PyYAML e Joblib:** utilizadas, respectivamente, para a leitura centralizada de configurações e para a serialização (persistência) eficiente dos artefatos treinados;

- **Streamlit:** Framework utilizado para o desenvolvimento do dashboard de operações, permitindo a criação de uma interface interativa para visualização de diagnósticos e probabilidades em tempo real;
- **Statsmodels:** Empregada nas etapas de diagnóstico de dados para testes de estacionariedade e análise de autocorrelação (ACF/PACF).

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta a análise dos resultados obtidos com a implementação do sistema inteligente de monitoramento proposto. A validação do modelo foi realizada conforme a estratégia metodológica descrita anteriormente, utilizando conjuntos de dados sintéticos gerados pelo modelo ARX para simular tanto o comportamento hidráulico normal da barragem quanto cenários de ruptura por *piping*.


A discussão está estruturada de modo a avaliar, primeiramente, a eficácia global do *ensemble* de detecção, demonstrando sua capacidade de classificação binária. Em seguida, detalha-se o desempenho individual dos algoritmos constituintes (LOF e Transformer VAE) e o processo de calibração dos limiares de decisão. Por fim, são abordadas a interpretabilidade do modelo (através da análise de importância das variáveis), a simulação de operação em tempo real (*modo replay*) e a verificação da robustez do sistema via método de Monte Carlo."

4.1 Desempenho global do sistema de detecção

O sistema proposto, composto por detectores de anomalia baseados em LOF e Transformer VAE integrados por um classificador LightGBM, apresentou desempenho global bastante satisfatório no conjunto de validação/teste rotulado conforme matriz de confusão final apresentada na Figura 7. Isso indica que o modelo praticamente sempre reconhece quando o comportamento de poropressão corresponde aos cenários de risco e, ao mesmo tempo, quase nunca classifica como anômalo um trecho que, de fato, está dentro do regime esperado.

Para a consolidação dos resultados apresentados na Matriz de Confusão, utilizou-se estritamente o conjunto de teste, que corresponde a uma parcela de 10% do *dataset* total gerado. Cabe ressaltar que o banco de dados completo compreende 23.000 janelas temporais divididas em 20.000 amostras de operação normal e 3.000 amostras de cenários de *piping*. Desta forma, a avaliação aqui exposta reflete o desempenho do modelo sobre as aproximadamente 2.300 amostras inéditas reservadas para esta etapa (isoladas do treinamento), confirmando que a precisão obtida não decorre de memorização (*overfitting*), mas sim da capacidade de generalização do sistema frente a novos dados.

Figura 7- Matriz de confusão



Fonte: Autor (2025)

Em termos de uso, essa configuração significa que o sistema produz uma quantidade muito pequena de alarmes indevidos e perde pouquíssimos eventos de piping. Ou seja, o operador não fica sobrecarregado com alertas falsos e, quando um aviso é emitido, tende a estar associado a um trecho da série temporal onde houve alteração significativa do regime hidráulico. Na Tabela 2 a seguir, têm-se o desempenho do modelo proposto:

Tabela 2- Métricas de desempenho

Métrica	Valor	Interpretação
Precisão	99,33%	Dos alertas, 99,3% são reais
Recall	99,33%	Detecta 99,3% dos piping
Especificidade	99,90%	99,9% dos normais corretos
F1-Score	99,33%	Equilíbrio precisão/recall
Taxa falsos alarmes	0,10%	Alarmes indevidos mínimos

Fonte: Autor (2025)

4.2 Desempenho dos detectores individuais e métricas AUC

A avaliação individual dos detectores revelou que o algoritmo LOF apresentou desempenho elevado na separação entre leituras normais e anômalas. As curvas de precisão-revocação e de ROC associadas ao LOF permanecem praticamente todo o tempo em região de alto desempenho, com área sob a curva de precisão-revocação (AUC-PR) em torno de 0,95 e área sob a curva ROC (AUC-ROC) próxima de 0,99 conforme a Tabela 3.

Tabela 3- Comparação de desempenho dos detectores

Detector	AUC-PR	AUC-ROC	Interpretação
LOF	0,95	0,99	Detecta desvios locais imediatos
Transformer VAE	0,83	0,93	Reconhece padrões temporais de longo prazo
Ensemble (final)	0,97	0,99	Decisão integrada

Fonte: Autor (2025)

Resultados similares foram obtidos por Silva, Caetano e Pierozan (2024), que reportaram precisão superior a 96% na predição de leituras piezométricas via regressão linear múltipla em grupos correlacionados (>90%), validando a robustez de métodos não-supervisionados para detecção de anomalias em dados hidráulicos reais da barragem Salto (GO)

Deste modo, os detectores analisam as séries de poropressão em janelas de tempo, gerando para cada janela um score de risco. Um componente estima o quão distante aquela janela está do “aglomerado” de observações normais; outro compara a curva observada com uma curva “esperada” reconstruída a partir do aprendizado do modelo. Quando a janela se comporta de forma parecida com casos normais, o score é baixo; quando se aproxima do padrão de piping usado no treinamento, o score aumenta.

Esses resultados indicam que, isoladamente, o LOF já é capaz de identificar a maior parte das ocorrências de piping com grande margem em relação ao acaso, mesmo sob forte desbalanceamento entre as classes.

O Transformer VAE, por sua vez, obteve AUC-PR em torno de 0,83 e AUC-ROC próxima de 0,93, valores também elevados, embora ligeiramente inferiores aos do LOF. As curvas associadas ao VAE mostram boa separação entre regimes, com manutenção de alta precisão para níveis relevantes de revocação, o que confirma que o modelo de VAE captura informações complementares sobre o padrão temporal de poropressão e contribui para robustez do sistema completo. A combinação dos dois detectores na forma de um ensemble permite explorar o ponto forte de cada abordagem, sintetizando a decisão final em uma métrica única de score utilizada pelo classificador supervisionado.

Na prática, isso significa que o sistema leva em conta a forma da evolução da poropressão, a tendência ao longo dos dias e a coerência entre sensores. Não se trata apenas de analisar um valor absoluto de nível d’água nos poros, mas de reconhecer combinações de

tendências (por exemplo, aumentos graduais em determinados piezômetros, mudança nas correlações entre eles e intensificação do gradiente hidráulico) que caracterizam o início de um processo de erosão interna.

4.3 Curvas PR/ROC do modelo e escolha do limiar


A fusão dos scores de anomalia no ensemble voltado para F2 (ensemble_F2) foi concebida para privilegiar recall alto, ou seja, priorizar a detecção de todos os eventos de piping, mesmo que isso gere alguns alertas extras. Isso é particularmente desejável em problemas de segurança de barragens, onde perder um evento real (falso negativo) tem custo potencialmente perigoso, muito superior ao de alguns alarmes indevidos (falsos positivos).

A calibração do limiar de decisão foi realizada de forma sistemática, utilizando simultaneamente três critérios práticos: maximização da métrica $F\beta$ com $\beta = 2$ (que dá mais peso à detecção de anomalias), limitação da taxa de falsos positivos (FPR) a valores inferiores a 5% e referência ao percentil 95 das observações normais. O valor final selecionado para o ensemble_F2 ficou em torno de 0,27 em termos simples, esse é o "ponto de alarme" onde o sistema diz "algo está errado".

Para transformar o score num alerta concreto, foi definido esse limiar de corte. Na calibração, escolheu-se um valor que mantém alta sensibilidade para piping, mas exige desvio real do histórico normal para disparar alarme, evitando que variações comuns sejam confundidas com risco.

O desempenho dos modelos base que compõem o sistema pode ser visualizado através de suas curvas características. A Figura 8 apresenta as Curvas ROC para os modelos LOF e Transformer VAE, respectivamente, evidenciando a capacidade de separação entre classes.


Figura 8 - Curvas ROC e precisão-revocação do LOF



Fonte: Autor (2025)

Já a Figura 9 detalha as curvas Precision-Recall (PR). Estas curvas são fundamentais para a estratégia do ensemble, pois refletem a região de trade-off entre sensibilidade (capacidade de achar piping) e especificidade.

Figura 9 - Curvas Precision-Recall (PR)



Fonte: Autor (2025)

Na prática, isso significa que a maior parte dos eventos de piping simulados é corretamente sinalizada. O sistema também incorpora limiar adaptativo para uso em produção, ajustando automaticamente o ponto de corte conforme a distribuição recente dos scores. Isso lida com deriva de dados (como mudanças graduais no regime hidráulico por sazonalidade ou manutenção) sem precisar re-treinar o modelo inteiro.

Do ponto de vista operacional, é simples: score abaixo de 0,27 indica barragem em situação normal; score acima indica "verificar agora". Os apenas 2 falsos positivos na matriz de confusão mostram que o limiar está calibrado para filtrar ruído diário, preservando a atenção do engenheiro para alertas realmente relevantes que indicam alteração significativa no regime hidráulico da estrutura.


4.4 Distribuição dos scores de anomalia

Os histogramas de distribuição dos scores de anomalia para os diferentes detectores evidenciam uma separação nítida entre o comportamento normal do sistema e os cenários anômalos simulados.

No caso do Transformer VAE, observa-se que as leituras normais concentram-se em valores baixos de erro de reconstrução, formando um pico bem definido próximo de zero, enquanto as anomalias apresentam uma distribuição mais dispersa, caracterizada por uma cauda pronunciada em valores mais elevados (Figura 10). O limiar adotado para o VAE, em torno de 0,02, coincide com a região onde essa cauda passa a se distanciar do corpo principal

da distribuição normal, favorecendo a redução de falsos positivos e assegurando que pequenas variações operacionais não sejam interpretadas como eventos críticos.

Figura 10 - Distribuição do score do Transformer




Fonte: Autor (2025)

No ensemble_F2, que representa o modelo final do sistema, a separação torna-se ainda mais evidente. As observações normais apresentam scores predominantemente abaixo de 0,22, enquanto episódios de piping simulados frequentemente atingem valores superiores a 0,8. Essa diferença clara de escala cria uma zona de segurança entre o comportamento normal e o limiar operacional adotado, facilitando a interpretação visual em séries temporais e aumentando a confiabilidade do sistema para uso contínuo em operação.

A Figura 11 ilustra essa segregação no ensemble, onde a linha vertical preta indica o limiar calibrado (0,2683). As linhas pontilhadas representam os critérios de suporte utilizados na calibração: maximização da métrica $F\beta$ (linha verde) e referência ao percentil 95 das observações normais (linha vermelha), evidenciando a consistência do processo de escolha do ponto de corte.

Figura 11 - Distribuição do score do modelo



Fonte: Autor (2025)


Para o LOF, o limiar selecionado também se posiciona próximo ao ponto em que a densidade de scores normais se torna muito baixa, reforçando a coerência entre os critérios de calibração adotados nos diferentes detectores que compõem o sistema.

4.5 Importância das variáveis e interpretação física

A análise da importância das variáveis no classificador LightGBM revela que o modelo utiliza predominantemente atributos agregados em janelas temporais mais longas, sobretudo *slopes* (declividades) e desvios-padrão calculados em janelas de 365 dias. Variáveis como *multi_365d_s0_slope*, *multi_365d_s4_std*, *multi_365d_s0_std* e *multi_365d_s4_slope* aparecem entre as mais relevantes, sugerindo que a detecção de piping é fortemente guiada por tendências graduais e aumentos de variabilidade ao longo de períodos de um ano.

A Figura 12 apresenta o ranking das 30 variáveis mais importantes utilizadas pelo modelo, corroborando a predominância de métricas de longo prazo e a forte contribuição do score de anomalia do LOF (*score_lof_0*) como atributo sintetizador.

Figura 12 - Variáveis importantes para a detecção



Fonte: Autor (2025)

Visto que a saída computacional do modelo preserva a nomenclatura original em inglês das *features*, o Quadro 2 detalha o significado físico e a função de cada variável listada no gráfico de importância, facilitando a interpretação dos resultados.

Quadro 2- Descrição das Features

Variável	Descrição / Significado Físico
score_lof_0	Resultado do detector LOF para o sensor 0. Indica a quão “isolada” está a leitura atual em relação à densidade local (valores altos indicam maior suspeita de anomalia)

multi_365d_sX_std (Ex: s0, s3)	Desvio-padrão das leituras do sensor X em uma janela móvel de 365 dias. Indica a volatilidade ou oscilação da poropressão ao longo de um ano.
head_ratio_outlet_foundation	Relação de carga hidráulica entre a saída e a fundação. Atua como indicador do gradiente global de percolação na estrutura.
multi_365d_sX_slope (Ex: s0, s4)	Inclinação da reta de tendência (<i>slope</i>) do sensor X em 365 dias. Indica se há uma tendência persistente de subida ou descida da pressão no longo prazo.
multi_180d_sX_std	Desvio-padrão das leituras do sensor X em uma janela de 180 dias (semestral).
multi_180d_sX_slope	Inclinação da tendência (<i>slope</i>) do sensor X em 180 dias.
multi_90d_sX_std / slope	Desvio-padrão e inclinação calculados para uma janela de 90 dias (trimestral), capturando variações sazonais mais curtas.
multi_365d_sX_delta_start	Diferença acumulada do valor do sensor X entre o início e o fim da janela de 365 dias. Representa a variação absoluta anual.
multi_180d_sX_delta_start	Diferença acumulada do valor do sensor X em 180 dias.
multi_365d_sX_pct_change	Variação percentual do valor do sensor X ao longo de 365 dias.
corr_sensor_0_4	Coeficiente de correlação entre os piezômetros 0 e 4. Mede o grau de interdependência linear entre as leituras (se oscilam juntos ou divergem).
score_ensemble_0	Pontuação combinada (<i>ensemble</i>) da janela atual. Representa a probabilidade final de anomalia baseada na fusão de todos os algoritmos.
multi_365d_s4_ewma_delta	Variação do sensor 4 em 365 dias suavizada por Média Móvel Exponencial (<i>EWMA</i>), filtrando ruídos de alta frequência.
multi_365d_s4_zscore	Z-score do sensor 4 em relação à média histórica de 365 dias. Indica quantos desvios-padrão a leitura atual está distante da média (detecção de <i>outliers</i>).
temp_diff_std_sX (Ex: s0, s1, s2)	Variação (desvio-padrão) da diferença de temperatura ou gradiente térmico no sensor X ao longo do tempo.
temp_slope_s4	Tendência de variação da temperatura no sensor 4.

Fonte: Autor (2025)

Essa evidência é coerente com o entendimento físico de processos de percolação em barragens, nos quais o desenvolvimento de trajetórias preferenciais e o enfraquecimento da estrutura costumam se materializar em mudanças sistemáticas de poropressão, mais do que em flutuações pontuais.

Outro resultado importante é a presença, entre as primeiras posições, da variável *head_ratio_outlet_foundation*, que expressa a relação entre a carga hidráulica na saída e na fundação. A relevância dessa variável indica que o modelo reconhece explicitamente a influência do gradiente hidráulico global no risco de *piping*, reforçando o papel do contexto físico no processo de decisão. Além dessas, correlações entre sensores (por exemplo, *corr_sensor_0_4*) e estatísticas de janelas intermediárias (90 e 180 dias) compõem uma visão completa do estado hidráulico da barragem.


Na prática, isso significa que o modelo não reage a variações pontuais ou ruídos isolados das leituras, mas sim a mudanças graduais e persistentes. Do ponto de vista da engenharia, esse comportamento alinha o sistema aos mecanismos físicos reais de erosão interna, que não se desenvolvem instantaneamente. Isso torna a ferramenta mais confiável para o monitoramento, pois reduz a probabilidade de alarmes falsos e direciona a atenção do engenheiro para alterações estruturais que realmente exigem inspeção.

4.6 Monitoramento em modo replay e séries temporais

Para validar a aplicabilidade prática da ferramenta, o sistema foi submetido a um teste de 'simulação operacional' (modo replay). Esse teste consiste em reproduzir cronologicamente todo o histórico de leituras dos instrumentos, como se o software estivesse ligado em tempo real na sala de controle dia após dia.

O objetivo foi verificar se o sistema geraria alarmes coerentes diante da evolução temporal das pressões. O gráfico da Figura 13 ilustra o comportamento do índice de anomalia (score) calculado para os 5 piezômetros do modelo proposto ao longo de um ano de operação simulada.

Figura 13 - Pontuação de confiança do modelo



Fonte: Autor (2025)

Observa-se que, durante os períodos de comportamento hidráulico normal (fundo estável), o índice de anomalia permanece baixo, respeitando a margem de segurança. No entanto, quando os dados inseridos correspondem a um cenário de *piping* (erosão interna), o índice dispara verticalmente, ultrapassando o limiar de alerta (linha tracejada em amarelo).

Esse comportamento demonstra que a ferramenta possui seletividade: ela ignora as flutuações naturais do dia a dia (ruídos de leitura, pequenas chuvas), mas reage de forma incisiva a alterações estruturais persistentes. Para o engenheiro residente, isso se traduz em confiança: o sistema não gera alertas desnecessários por qualquer variação, chamando a atenção apenas quando há uma tendência clara de fuga do padrão de segurança estabelecido.

4.7 Robustez, Monte Carlo e reprodutibilidade

Para garantir a confiabilidade do sistema como ferramenta de segurança, a solução foi submetida a uma análise de robustez baseada no método de Monte Carlo. O objetivo foi verificar se o desempenho do detector se mantém estável mesmo diante de incertezas inerentes aos dados de campo e pequenas variações nos parâmetros de calibração.

Foram realizadas múltiplas simulações (rodadas de teste) introduzindo perturbações controladas nas amostras de treinamento. As métricas de desempenho obtidas apresentaram baixa variância, indicando que o modelo não depende de uma "configuração de sorte", mas sim que aprendeu os padrões hidráulicos fundamentais da estrutura. Dentre os cenários simulados, a configuração que apresentou o melhor equilíbrio entre sensibilidade e estabilidade foi promovida a modelo final.

A Tabela 4 apresenta o resumo do desempenho obtido nas cinco rodadas de teste, destacando a consistência dos resultados.

Tabela 4 - Resumo dos desempenhos das simulações

Simulação (rodada)	Desempenho LOF (AUC)	Desempenho VAE (AUC)	Alarmes falsos (FP)	Falhas de detecção (FN)
Rodada 01 (Selecionada)	0.988	0.929	2	2
Rodada 02	0.994	0.895	2	2
Rodada 03	0.989	0.857	1	4
Rodada 04	0.986	0.841	1	7
Rodada 05	0.989	0.806	2	4
Média	0.989	0.866	1.6	3.8

Fonte: Autor (2025)

A reprodutibilidade do processo é assegurada pela organização dos arquivos de projeto. Todos os componentes calibrados (o ensemble de detecção, os parâmetros de normalização e os limiares de decisão) são persistidos em diretórios controlados.

Além disso, o uso de parâmetros de inicialização fixos (*seeds*) permite que qualquer engenheiro ou possa reexecutar o processo de treinamento e chegar exatamente aos mesmos resultados apresentados neste trabalho. Essa rastreabilidade transforma o sistema de uma "caixa preta" em um fluxo de trabalho transparente e validado, adequado às exigências de monitoramento de infraestruturas.

4.8 Erros residuais e limitações observadas

Apesar do desempenho muito favorável, o sistema ainda apresenta alguns erros residuais que merecem discussão. Os falsos positivos remanescentes tendem a ocorrer em trechos de série temporal marcados por ruído mais intenso ou transientes rápidos, em que há elevação abrupta do score sem que o evento corresponda a um cenário genuíno de piping. Nesses casos, há espaço para uso de limiar adaptativo mais conservador ou de filtros pós-processamento, capazes de exigir persistência do sinal de anomalia por determinado intervalo antes de gerar um alerta ao operador, reduzindo ainda mais a taxa de alarmes espúrios.

No que diz respeito aos falsos negativos, que somaram apenas dois casos no conjunto de teste, observa-se que em geral eles se encontram muito próximos do limiar de decisão. Esses eventos podem ser interpretados como situações limítrofes, em que o padrão de poropressão se aproxima do comportamento anômalo, mas sem se afastar de forma tão marcante das séries normais. A redução desse número pode ser buscada em trabalhos futuros por meio de ajustes finos no $F\beta$ utilizado na calibração, de enriquecimento dos cenários sintéticos de piping (em especial aqueles de intensidade intermediária) e de eventual incorporação de novos atributos físicos que capturem melhor a transição entre regime seguro e regime crítico.

5 CONCLUSÃO

O presente trabalho atingiu seu objetivo geral ao desenvolver e validar um sistema autônomo de monitoramento de barragens capaz de detectar anomalias associadas ao fenômeno de *piping* em barragens de terra. A integração proposta entre simulação hidrodinâmica via modelo ARX e um *ensemble* de algoritmos de *Machine Learning* demonstrou ser uma abordagem robusta para superar as limitações dos métodos tradicionais de monitoramento manual ou puramente baseados em limiares estáticos.

A metodologia empregada permitiu concluir que a fusão de detectores não supervisionados (Transformer VAE e LOF) com um classificador supervisionado (LightGBM) oferece uma camada de segurança superior ao uso de modelos isolados. Os resultados obtidos nas simulações, com Precisão e Recall de 99,33% e uma taxa de falsos alarmes inferior a 0,10%, validam a eficácia do sistema em distinguir anomalias reais de ruídos operacionais e flutuações climáticas naturais. A escolha da métrica F2-Score para a calibração dos limiares mostrou-se acertada, priorizando a sensibilidade do sistema à detecção de falhas (minimizando falsos negativos), o que é fundamental no contexto de segurança de barragens.

Do ponto de vista físico e geotécnico, a análise da importância das variáveis (feature importance) revelou que o modelo aprendeu a priorizar tendências de longo prazo (desvios e declividades em janelas de 365 dias) e correlações entre sensores, em detrimento de variações pontuais. Isso confirma a hipótese de que o *piping*, sendo um processo de erosão regressiva, manifesta-se através de alterações progressivas no comportamento hidráulico da estrutura, e que a inteligência artificial é capaz de capturar essa assinatura temporal complexa.

O teste de robustez via método de Monte Carlo e a validação em "modo replay" asseguraram que o sistema mantém estabilidade e confiabilidade mesmo diante de incertezas paramétricas e variabilidade dos dados de entrada. A implementação de limiares adaptativos demonstrou ser uma funcionalidade essencial para a operação contínua, permitindo que o monitoramento se ajuste a derivas sazonais sem gerar alertas espúrios excessivos.

Apesar do desempenho satisfatório, o estudo identificou limitações, como a dependência de dados sintéticos para o treinamento inicial e a ocorrência residual de falsos positivos em cenários de ruído intenso. Como trabalhos futuros, sugere-se a aplicação do sistema em dados reais de barragens instrumentadas, a integração direta com hardware IoT (processamento na borda/*edge computing*) e a expansão do modelo para incluir outras variáveis de instrumentação, como vazão de drenos e deslocamentos medidos por inclinômetros.

Em suma, a solução proposta contribui significativamente para a modernização da engenharia de barragens, alinhando-se às diretrizes da Política Nacional de Segurança de Barragens (PNSB) e oferecendo uma ferramenta preditiva que potencializa a tomada de decisão, reduz riscos operacionais e promove maior segurança para a infraestrutura e para a sociedade.

REFERÊNCIAS

AGUIRRE, Luis Antonio. **Introdução à identificação de sistemas: técnicas lineares e não-lineares aplicadas a sistemas reais**. 4. ed. Belo Horizonte: Editora UFMG, 2015

ANDRADE, G. *et al.* Abordagem iWater: uma contribuição ao monitoramento da Barragem Santa Bárbara no cenário da IoT. Pelotas: Universidade Católica de Pelotas, 2018.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 6484**: solo — sondagens de simples reconhecimento com SPT — método de ensaio. Rio de Janeiro: ABNT, 2020.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 7182**: solo — ensaio de compactação. Rio de Janeiro: ABNT, 2021.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 8681**: ações e segurança nas estruturas — procedimento. Rio de Janeiro: ABNT, 2021.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 11682**: estabilidade de encostas. Rio de Janeiro: ABNT, 2009.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 13028**: elaboração e apresentação de projetos geotécnicos — aterros e taludes de estabilização. Rio de Janeiro: ABNT, 2017.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 14545**: solo — determinação do coeficiente de permeabilidade de solos argilosos em carga variável. Rio de Janeiro: ABNT, 2000.

BARROS, Matheus Lima de. **Machine learning aplicado à previsão de piping em barragens de terra homogêneas**. 2020. 97 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) — Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2020. Disponível em: https://bdm.unb.br/bitstream/10483/30542/1/2020_MatheusLimaDeBarros_tcc.pdf. Acesso em: 12 out. 2025.

BEN-KIKI, Oren; EVANS, Clark; D'ANJOU, Ingy. **YAML Ain't Markup Language (YAML™) Version 1.2**. [S. l.]: YAML.org, 2021. Disponível em: <https://yaml.org/spec/1.2.2/>. Acesso em: 10 nov. 2025.

BRAGIONI, Débora de Oliveira. **Aplicação dos níveis de controle no monitoramento piezométrico em um estudo de caso em barragem de mineração**. 2022. 56 f. Monografia (Graduação em Engenharia Civil) — Escola de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2022. Disponível em: <https://www.monografias.ufop.br/handle/35400000/5083>. Acesso em: 14 out. 2025.

BRASIL. **Lei nº 12.334, de 20 de setembro de 2010**. Estabelece a Política Nacional de Segurança de Barragens [...]. Diário Oficial da União: seção 1, Brasília, DF, 21 set. 2010.

BRASIL. Agência Nacional de Águas. **Resolução nº 91, de 17 de abril de 2012**. Estabelece a classificação de barragens quanto ao Dano Potencial Associado (DPA) e dá outras providências. Diário Oficial da União: seção 1, Brasília, DF, 18 abr. 2012.

BRASIL. Agência Nacional de Águas. **Resolução nº 143, de 4 de junho de 2012**. Estabelece a periodicidade de atualização e a qualificação do responsável técnico pela subscrição dos Relatórios de Inspeção de Segurança Regular e Especial de barragens [...]. Diário Oficial da União: seção 1, Brasília, DF, 5 jun. 2012.

BRASIL. Agência Nacional de Águas. **Resolução nº 236, de 27 de novembro de 2017**. Estabelece diretrizes para a elaboração do Plano de Segurança da Barragem, define seu conteúdo mínimo e o dos Relatórios de Inspeção de Segurança, e dá outras providências. Diário Oficial da União: seção 1, Brasília, DF, 28 nov. 2017.

BRASIL. Agência Nacional de Mineração. **Resolução nº 32, de 28 de maio de 2020**. Estabelece os prazos e os requisitos técnicos para a descaracterização de barragens alteadas pelo método a montante [...]. Diário Oficial da União: seção 1, Brasília, DF, 2 jun. 2020.

CRAIG, R. F. **Craig's soil mechanics**. 8. ed. London: Spon Press, 2012.

EBO GEOTECH. **IA e monitoramento digital: o futuro da gestão de barragens e rejeitos**. 2025. Disponível em: <https://ebogeotech.com/ia-e-monitoramento-digital-o-futuro-da-gestao-de-barragens-e-rejeitos/>. Acesso em: 14 dez. 2025.

ECMA INTERNATIONAL. **The JSON Data Interchange Standard (ECMA-404)**. 2. ed. Geneva: ECMA, 2017.

GACU, P. A. *et al.* Artificial Intelligence and Hydrological Modeling for Dam Safety Management and Water Resource Prediction. **Journal of Environmental Systems and Engineering**, v. 12, n. 1, p. 1-18, 2025.

GHOSH, A.; EDWARDS, D. J.; HOSSEINI, M. R. Patterns and trends in Internet of Things (IoT) research: future applications in the construction industry. **Engineering, Construction and Architectural Management**, v. 27, n. 8, p. 1853-1878, 2020.

GREENHILLS OPERATIONS. **Tailings Storage Facility – Annual Performance and Review Report 2021**. Perth: Golder Associates, 2021.

HILDEBRANDT, Tim; SNOOK, Jason. **Mastering MQTT: discover how to securely leverage MQTT for IoT and M2M communication**. Birmingham: Packt Publishing, 2023.

IRAZÁBAL, J. *et al.* Detection of outliers in dam monitoring time series with autoencoders. **Journal of Civil Structural Health Monitoring**, v. 15, p. 1-20, 2025.

INTERNATIONAL COMMISSION ON LARGE DAMS (ICOLD). **Automated dam monitoring systems: guidelines and case studies**. Paris: ICOLD, 2000. (Bulletin 118). Disponível em: <https://www.icold-cigb.org/GB/publications/bulletins.asp>. Acesso em: 22 dez. 2025.

INOVA CIVIL. **Barragens na engenharia: tipos e patologias**. Disponível em: <https://inovacivil.com.br/barragens/>. Acesso em: 23 dez. 2025.

LARA, Pedro Guilherme de. **Metodologia probabilística de previsão de brecha de ruptura de barragens**. 2016. 181 f. Dissertação (Mestrado em Engenharia Ambiental) — Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, SC, 2016.

LIMA NETO, Francisco Felinto de. **Estudo do comportamento geomecânico compactado e indeformado de um solo residual tropical da formação barreiras em Bananeiras/PB**. 161 f. Mestrado em Engenharia Civil e Ambiental. UFRN, Natal/RN. 2025.

LUTZ, Mark. **Learning Python**. 5. ed. Sebastopol: O'Reilly Media, 2013.

MACHADO, William Gladstone de Freitas. **Monitoramento de barragens de contenção de rejeitos da mineração**. 2007. 155 f. Dissertação (Mestrado em Engenharia) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2007.

ROBERTSON, P. K., MELO, L., WILLIAMS, D. J., WILSON, G. W. **Relatório do painel de especialistas sobre as causas técnicas do rompimento da barragem i do córrego do feijão painel de especialistas**. 2019.

REVISTA MINÉRIOS & MINERAIS. **Como funcionam os sensores IoT para monitorar barragens de mineração**. 2025. Disponível em: <https://revistaminerios.com.br/sensores-iot-monitorar-barragens-mineracao/>. Acesso em: 22 out. 2025.

RIBEIRO, L. S. **Definição dos níveis de controle piezométricos para uma barragem de contenção de rejeitos utilizando modelagem numérica**. 2023. Monografia (Graduação em Engenharia Civil) — Universidade Federal de Lavras, Lavras, 2023.

RUMA, J. F. *et al.* Particle swarm optimization based LSTM networks for water level forecasting: a case study on Bangladesh river network. **Results in Engineering**, v. 17, 100951, 2023. DOI: 10.1016/j.rineng.2023.100951. Disponível em: <https://doi.org/10.1016/j.rineng.2023.100951>. Acesso em: 14 nov. 2025.

SILVA, A. B.; CAETANO, M. R.; PIEROZAN, R. C. Aplicação de métodos estatísticos em piezômetros como auxílio ao monitoramento de barragens. In: **CONGRESSO BRASILEIRO DE MECÂNICA DOS SOLOS E ENGENHARIA GEOTÉCNICA (COBRAMSEG)**, 20., 2024, Balneário Camboriú. Anais... Balneário Camboriú: ABMS, 2024. p. 269-276.

SILVA, João Vitor Alves Gomes da; GARCIA, Paulo Roberto. Segurança de barragens: um modelo inteligente para a detecção de anomalias em dados de instrumentação. **Revista Caderno Pedagógico**, [S.l.], v. 22, n. 10, 2025. ISSN 1983-0882. DOI: 10.54033/cadpedv22n10-125. Disponível em: <https://doi.org/10.54033/cadpedv22n10-125>. Acesso em: 13 set. 2025.

SOUZA, T. L. *et al.* **Sistemas ciberfísicos inteligentes para detecção de eventos geotécnicos críticos: integração entre IoT e IA**. São José dos Campos: Instituto Tecnológico de Aeronáutica, 2023.

UMESHA, P. K. *et al.* Low-cost wireless sensing and IoT integration for hydrological and geotechnical monitoring. **Environmental Earth Sciences**, v. 80, n. 3, 2021.

VALE / Coffey (2016): Estudos Comparativos e Avaliação de Piezômetros de Corda Vibrante e Casagrande, 234p

XIE, Changjiang. Research and application of key technologies for dam safety monitoring based on LoRa. **IOP Conference Series: Earth and Environmental Science**, [S. l.], v. 768, p. 012131, 2021. DOI 10.1088/1755-1315/768/1/012131. Disponível em: <https://iopscience.iop.org/article/10.1088/1755-1315/768/1/012131>. Acesso em: 15 out. 2025.

YAQOOB, I. *et al.* Internet of Things architecture: recent advances, taxonomy, requirements, and open challenges. **IEEE Wireless Communications**, v. 24, n. 3, p. 10-16, 2017.