



**INSTITUTO
TECNOLÓGICO
VALE**

**Programa de Pós-Graduação em Instrumentação, Controle e
Automação de Processos de Mineração (PROFICAM)
Escola de Minas, Universidade Federal de Ouro Preto (UFOP)
Associação Instituto Tecnológico Vale (ITV)**

Dissertação

**PREVISÃO DE CURTO PRAZO PARA GEOTECNIA: INVESTIGAÇÃO E
PROPOSTA DE UM MÉTODO PARA ANÁLISE E PREDIÇÃO PIEZOMÉTRICA EM
BARRAGENS DE REJEITO**

Mayron Cesar da Silva Nogueira

**Ouro Preto
Minas Gerais, Brasil
2022**

Mayron Cesar da Silva Nogueira

**PREVISÃO DE CURTO PRAZO PARA GEOTECNIA: INVESTIGAÇÃO E
PROPOSTA DE UM MÉTODO PARA ANÁLISE E PREDIÇÃO PIEZOMÉTRICA EM
BARRAGENS DE REJEITO**

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador: Prof. Gustavo Pessin, Ph.D

Coorientador: Prof. Juan Manuel Girao Sotomayor, D.Sc.

Ouro Preto

2022

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

N778p Nogueira, Mayron Cesar da Silva.

Previsão de curto prazo para geotecnia [manuscrito]: investigação e proposta de um metodo para análise e predição piezométrica em barragens de rejeito. / Mayron Cesar da Silva Nogueira. - 2022.

70 f.: il.: color., gráf., tab.. + Equação.

Orientador: Prof. Dr. Gustavo Pessin.

Coorientadores: Profa. Dra. Janine Rodrigues Figueiredo, Prof. Dr. Juan Manuel Girão Sotomayor.

Dissertação (Mestrado Profissional). Universidade Federal de Ouro Preto. Programa de Mestrado Profissional em Instrumentação, Controle e Automação de Processos de Mineração. Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração.

Área de Concentração: Engenharia de Controle e Automação de Processos Minerais.

1. Aprendizado do computador. 2. Piezômetro. 3. Algoritmos computacionais - Adaboost. 4. Redes neurais (Computação) - Redes Neurais Artificiais. 5. Barragens de rejeitos. 6. Algoritmos computacionais - Floresta Radômica. 7. Algoritmos computacionais - Gradient Descent. 8. Algoritmos computacionais - Estocástico Descendente. I. Figueiredo, Janine Rodrigues. II. Pessin, Gustavo. III. Sotomayor, Juan Manuel Girão. IV. Universidade Federal de

Ouro Preto. V. Título.
Biblioteca Responsável: Maria Augusta Gomes Lima - Universidade Federal de



FOLHA DE APROVAÇÃO

Mayron Cesar da Silva Nogueira

Previsão de curto prazo para geotecnia: Investigação e proposta de um método para análise e predição piezométrica em barragens de rejeito

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração (PROFICAM), Convênio Universidade Federal de Ouro Preto/Associação Instituto Tecnológico Vale - UFOP/ITV, como requisito parcial para obtenção do título de Mestre em Engenharia de Controle e Automação na área de concentração em Instrumentação, Controle e Automação de Processos de Mineração

Aprovada em 18 de novembro de 2022

Membros da banca

Doutor - Gustavo Pessin - Orientador - Instituto Tecnológico Vale
Doutor - Juan Manuel Girao Sotomayor - Instituto Tecnológico Vale
Doutora - Janine Rodrigues Figueiredo - Instituto Tecnológico Vale
Doutor - Caetano Mazzoni Ranieri - Universidade de São Paulo

Gustavo Pessin, orientador do trabalho, aprovou a versão final e autorizou seu depósito no Repositório Institucional da UFOP em 18/11/2022



Documento assinado eletronicamente por **Bruno Nazário Coelho, COORDENADOR(A) DE CURSO DE PÓS-GRADUAÇÃO EM INST. CONTROLE AUTOMAÇÃO DE PROCESSOS DE MINERAÇÃO**, em 29/11/2022, às 10:39, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0433643** e o código CRC **DAB9E40F**.

Referência: Caso responda este documento, indicar expressamente o Processo nº 23109.015965/2022-16

SEI nº
0433643

R. Diogo de Vasconcelos, 122, - Bairro Pilar Ouro Preto/MG, CEP 35402-163
Telefone: (31)3552-7352 - www.ufop.br

*Dedico este trabalho à minha
esposa Angela que durante todo
esse período me apoiou e foi meu
esteio durante os períodos mais
turbulentos, meus pais José e Kátia
que por toda vida se dedicaram a
deixar o legado do estudo e
honestidade acima de tudo a mim e
minhas irmãs Bruna e Joyce, ao
meu filho Luca que chega para
iluminar nossas vidas. E por fim a
Vale que me proporcionou
condições para realizar um sonho
de vida que é me tornar um mestre
em automação industrial, profissão
pela qual me dediquei por quase
toda minha vida.*

*“Esvazie sua mente, não tenha formato. Sem contornos, como água. Se você colocar a água em um copo, ela se torna o copo. Você coloca a água em uma garrafa e ela se torna a garrafa. Você a coloca em uma chaleira, e ela se tornará chaleira. Agora, a água pode fluir ou pode destruir. Seja água, meu amigo.” Seja resiliente e adaptável.
(Bruce Lee)*

Resumo

Resumo da Dissertação apresentada ao Programa de Pós Graduação em Instrumentação, Controle e Automação de Processos de Mineração como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

PREVISÃO DE CURTO PRAZO PARA GEOTECNIA: INVESTIGAÇÃO E PROPOSTA DE UM MÉTODO PARA ANÁLISE E PREDIÇÃO PIEZOMÉTRICA EM BARRAGENS DE REJEITO

Mayron Cesar da Silva Nogueira

Setembro/2022

Orientadores: Gustavo Pessin

Juan Manuel Girao Sotomayor

É cada vez mais importante monitorar de forma ágil e precisa estruturas geotécnicas. Recentemente, diversos instrumentos e sistemas têm sido utilizados para monitoramento de condições em tempo real, em alta frequência e com alta qualidade. Nessa dissertação, passamos pelo entendimento básico das estruturas de barragem, instrumentação aplicadas a estas para enfim buscamos estender ainda mais a capacidade dos sistemas de monitoramento de estruturas geotécnicas por meio de sistemas preditivos. Propomos, desenvolvemos e avaliamos um sistema preditivo baseado em aprendizado de máquina para sensores do tipo piezômetro de corda vibrante automatizado, localizados em barragem de rejeito. Os dados observados e utilizados nos modelos preditivos são obtidos de uma barragem de rejeitos real, e para as predições do modelo, utilizamos dados históricos de réguas de nível, pluviometria e piezômetros. Investigamos diversos métodos de aprendizado de máquina, tais como: Floresta Randômica, Adaboost, Redes Neurais, Regressão Linear, Árvore de Decisão e Gradiente Estocástico, com o objetivo de encontrar o método que apresenta a maior taxa de acerto nas predições para 1, 3 e 7 dias posteriores à medição atual. O sistema proposto tem como finalidade o apoio na tomada de decisão por geotécnicos que operam e monitoram barragens de rejeito frente aos controles de nível das mesmas. Para fins de validação do método, dividimos a barragem nas seções de fundação e tapete de barragens, onde atingimos mais de 95% de predições com erro inferior a 20cm de variação. E considerando a mesma predição para 1, 3 e 7 dias posteriores à medição atual a

camada de aterro, atingimos mais de 95% das previsões com erro inferior a 20 cm considerando 1 dia após a medição atual.

Palavras-chave: Aprendizagem de máquina, Piezômetro, Adaboost.

Macrotema: Mina; **Linha de Pesquisa:** Tecnologias da Informação, Comunicação e Automação Industrial; **Tema:** Redução de Variabilidade e Melhoria de Controle;

Abstract

Abstract of Dissertation presented to the Graduate Program on Instrumentation, Control and Automation of Mining Process as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

SHORT TERM PREDICTION FOR GEOTECHNICAL: INVESTIGATION AND PROPOSAL OF METHOD FOR ANALYSIS AND PREDICTION FOR PIEZOMETRIC ALERTS IN TAILINGS DAMS

Mayron Cesar da Silva Nogueira

September/2022

Advisors: Gustavo Pessin

Juan Manuel Girao Sotomayor

It's increasingly important to monitor geotechnical structures in an quickly and accurate way. Recently, several instruments and systems have been used for monitoring conditions in real time, at high frequency and high quality data. In this dissertation, through the basic understanding of dam structures, instrumentation applied to them to finally seek further extend the capacity of monitoring systems of geotechnical structures through predictive systems. We propose, developed and evaluated a predictive system based on machine learning for automated wiring vibrating piezometer sensors located in tailings dams. The data observed and used in the predictive models are obtained from a real tailing dam, and for the model predictions, we used historical data from level meters, pluviometry and piezometers. We investigated several machine learning methods, such as: Random Forest, Adaboost, Neural Networks, Linear Regression, Decision Tree and Stochastic Gradient, with the objective of finding the method that presents the highest accuracy rate in the predictions for 1, 3 and 7 days forecast trending from the current measurement. The proposed system is aimed at supporting decision-making by geotechnicians who operate and monitor tailings dams against their level controls. For method validation purposes, we divided the dam into foundation and dam mat sections, where we achieved more than 95% of predictions with an error of less than 20cm of variation. And considering the same prediction for 1, 3 and 7 days after the current measurement of the landfill layer, we reached more than 95% of the prediction with an error of less than 20 cm considering 1 day after the current measurement.

Keywords: Machine Learning, Piezometer, Adaboost.

Macrotheme: Mine; **Research Line:** Information Technology, Communication and Industrial Automation; **Theme:** Variability Reduction and Controls Improvement;

Lista de Figuras

Figura 1.1	Arquitetura Básica do Sistema de Coleta de Instrumentação Geotécnica. . .	14
Figura 2.1	Dique Inicial de uma Barragem de Rejeitos.	17
Figura 2.2	Alteamento a jusante em uma barragem de rejeitos.	18
Figura 2.3	Dique inicial com rejeito adensado à montante da barragem de rejeitos. . .	18
Figura 2.4	Barragem de rejeito com alteamento à montante sobre o rejeito adensado. .	18
Figura 2.5	Barragem de rejeito com alteamento ao centro.	19
Figura 2.6	Tempo de resposta para 95% de equalização.	20
Figura 2.7	Piezômetro Casagrande.	20
Figura 2.8	Medição de piezômetro Casagrande em relação ao nível do mar.	21
Figura 2.9	Piezômetro de Corda Vibrante.	22
Figura 2.10	Medição de piezômetro elétrico de corda vibrante em relação ao nível do mar.	23
Figura 2.11	Medidor de Nível d'Água.	23
Figura 2.12	Medição de vazão de dreno de fundo, representado pela tubulação na parte debaixo da Figura.	24
Figura 2.13	Medição de vazão mássica na calha parshall instalada á jusante da barragem.	25
Figura 2.14	Esquema de funcionamento de um pluviômetro.	26
Figura 3.1	Arquitetura padrão de uma MLP.	29
Figura 3.2	Exemplo do processo do Adaboost.	30
Figura 3.3	Estrutura Geral de uma Árvore de Decisão.	31
Figura 3.4	Arquitetura típica da Floresta Randômica.	31
Figura 4.1	Metodologia de criação dos sistema preditivo.	35
Figura 4.2	Comportamento do acumulado de chuva no período de fev/2021 à mai/2022 para análise	37
Figura 4.3	Comportamento da variação do nível do reservatório para o período de fev/2021 à mai/2022 para análise.	38
Figura 4.4	Comportamento de um piezômetro localizado no tapete da barragem no período de fev/2021 à mai/2022.	39
Figura 4.5	Comportamento de um piezômetro de fundação localizado na parte central da barragem no período de abr/2021 à mai/2022.	40

Figura 4.6	Comportamento de um piezômetro de fundação localizado na ombreira esquerda da barragem no período de fev/2021 à mai/2022.	41
Figura 4.7	Comportamento de um piezômetro do aterro localizado na faixa central da barragem no período de abr/2021 à mai/2022.	42
Figura 4.8	Proposta de Regressor para Predição da Pressão Futura da Piezometria da Seção Crítica da Bacia da Barragem.	43
Figura 4.9	Arquitetura de testes e validação do modelo de predição dos valores da piezometria.	45
Figura 5.1	Análise de sensibilidade do piezômetro localizado no tapete da barragem. .	48
Figura 5.2	Análise de sensibilidade da predição T-PZ-001 previsão para um dia à frente em relação ao dia atual de processamento.	49
Figura 5.3	Análise de sensibilidade da predição T-PZ-001 previsão para três dias à frente em relação ao dia atual de processamento.	50
Figura 5.4	Análise de sensibilidade da predição T-PZ-001 previsão para sete dias à frente em relação ao dia atual de processamento.	50
Figura 5.5	Análise de sensibilidade da predição F-PZFC-001 previsão para um dia à frente em relação ao dia atual de processamento.	51
Figura 5.6	Análise de sensibilidade da predição F-PZFC-001 previsão para três dias à frente em relação ao dia atual de processamento.	52
Figura 5.7	Análise de sensibilidade da predição F-PZFC-001 previsão para sete dias à frente em relação ao dia atual de processamento.	52
Figura 5.8	Análise de sensibilidade da predição F-PZOE-001 previsão para um dia à frente em relação ao dia atual de processamento.	53
Figura 5.9	Análise de sensibilidade da predição A-PZ-001 previsão para um dia à frente em relação ao dia atual de processamento.	54
Figura 5.10	Análise de sensibilidade da predição A-PZ-001 previsão para três dias à frente em relação ao dia atual de processamento.	55
Figura 5.11	Análise de sensibilidade da predição A-PZ-001 previsão para sete dias à frente em relação ao dia atual de processamento.	56

Lista de Tabelas

Tabela 4.1	Exemplo da criação de série temporal histórica PASSADO para um instrumento de entrada no regressor.	44
Tabela 4.2	Exemplo da criação de série temporal histórica FUTURO para um instrumento de entrada no regressor.	44
Tabela 5.1	Avaliação dos resultados dos algoritmos X critérios de avaliação, T-PZ-001 D+1.	57
Tabela 5.2	Avaliação dos resultados dos algoritmos X critérios de avaliação, T-PZ-001 D+3.	57
Tabela 5.3	Avaliação dos resultados dos algoritmos X critérios de avaliação, T-PZ-001 D+7.	57
Tabela 5.4	Avaliação dos resultados dos algoritmos X critérios de avaliação, F-PZFC-001 D+1.	58
Tabela 5.5	Avaliação dos resultados dos algoritmos X critérios de avaliação, F-PZFC-001 D+3.	58
Tabela 5.6	Avaliação dos resultados dos algoritmos X critérios de avaliação, F-PZFC-001 D+7.	59
Tabela 5.7	Avaliação dos resultados dos algoritmos X critérios de avaliação, F-PZFOE-001 D+1.	59
Tabela 5.8	Avaliação dos resultados dos algoritmos X critérios de avaliação, A-PZ-001 D+1.	60
Tabela 5.9	Avaliação dos resultados dos algoritmos X critérios de avaliação, A-PZ-001 D+3.	60
Tabela 5.10	Avaliação dos resultados dos algoritmos X critérios de avaliação, A-PZ-001 D+7.	61

Sumário

1	Introdução	13
1.1	Motivação	13
1.2	Objetivos	15
1.2.1	Objetivos Específicos	15
1.3	Organização do Trabalho	15
2	O Ambiente de Barragem e os Instrumentos Mais Comuns no Monitoramento	17
2.1	Tipos de Barragens de acordo com seus Métodos Construtivos	17
2.1.1	Método a Jusante	17
2.1.2	Método a Montante	18
2.1.3	Método ao Centro	19
2.2	Piezômetros	19
2.2.1	Piezômetros Casagrande	19
2.2.2	2.1.2. Piezômetros Elétricos de Corda Vibrante	21
2.3	Medidor de Nível d'Água	23
2.4	Medição de vazão	24
2.5	Pluviômetro	25
3	Trabalhos Relacionados e Fundamentação Teórica	27
3.1	Métodos Supervisionados de Aprendizado de Máquina	27
3.1.1	Redes Neurais Artificiais, ANN	27
3.1.2	Adaboost	29
3.1.3	Árvore de Decisão	30
3.1.4	Floresta Randômica	31
3.1.5	Regressão Linear	32
3.1.6	Gradiente Estocástico Descendente	32
3.2	Trabalhos Relacionados sobre Algoritmos Inteligentes na Geotecnia	32
4	Proposta de Sistema Preditivo	35
4.1	Entendimento do Problema	35
4.2	Coleta, tratamento e Processamento de Dados	36

4.2.1	Coleta dos Dados	36
4.2.2	Tratamento dos Dados	37
4.2.3	Processamento de Dados	44
4.3	Investigação de Algoritmos de Inteligência Artificial	46
4.4	Investigação do Impacto da Confiabilidade na Predição	46
4.4.1	Coeficiente de Determinação	46
4.4.2	Raiz Quadrada do Erro Médio	46
4.4.3	Erro Médio Absoluto	47
4.4.4	Erro Médio Quadrático	47
5	Resultados e Discussões	48
5.1	Investigação dos Algoritmos de Inteligência Artificial	48
5.1.1	Análise Algoritmos para o Piezômetro T-PZ-001, previsão do Tapete para 1, 3 e 7 dias á frente em relação ao dia atual	48
5.1.2	Análise de Algoritmos Para o Piezômetro F-PZFOE01_MCA, Fundação Ombreira Esquerda D+1	53
5.1.3	2.3.4. Análise algoritmos para o piezômetro A-PZ-001_MCA, Aterro D+1, D_3 e D+7	53
5.2	Investigação do Impacto de Confiabilidade da Predição	56
5.2.1	Análise Confiabilidade para o Piezômetro T-PZ-001, Tapete D+1, D+3 e D+7	56
5.2.2	Análise Confiabilidade para o Piezômetro F-PZFC01_MCA, Fundação Central D+1, D+3 e D+7	57
5.2.3	Análise Confiabilidade para o Piezômetro F-PZFOE01_MCA, Fundação Ombreira Esquerda D+1, D+3 e D+7	59
5.2.4	Análise Confiabilidade para o Piezômetro A-PZ-001_MCA, Aterro D+1, D+3 e D+7	59
5.3	Análise dos resultados frente a operação de barragens	61
6	Conclusão	62
7	Trabalhos Futuros	63
	Referências Bibliográficas	65

1. Introdução

1.1. Motivação

Após acidentes ocorridos no Brasil relacionados a rompimentos de barragens de rejeitos de mineração, o tema recebeu forte atenção dos órgãos públicos, mídia e das próprias empresas donas dessas barragens.

A Agência Nacional de Mineração (ANM) através das resoluções 70.389, 13 e 51, estabeleceu diversos requisitos mínimos obrigatórios que foram impostos às mineradoras que possuem barragens classificadas como Dano Potencial Alto (DPA), dentre estas restrições se destacam:


1. Filmar em caráter 24x7 as estruturas nos pontos de rompimento;
2. Armazenar por 90 dias ininterruptos as imagens de cada câmera das barragens;
3. Automatizar a instrumentação básica, composta por:
 - (a) Piezômetros;
 - (b) Medidor de nível d'água;
 - (c) Medidor de vazão do extravasor;
 - (d) Régua de nível;
4. Implantar o acionamento manual e remoto das sirenes de emergência;
5. Implantar sistema de acionamento automático de sirenes.

Atualmente existem 600 instrumentos instalados em 12 barragens de DPA Alto e Médio no Corredor Norte, fonte própria. E com a implantação do CMG-NORTE, Centro de Monitoramento Geotécnico do Norte, que conta com nova estrutura operacional, se faz necessário apoiar a operação na identificação antecipada dos níveis de alteração dos piezômetros e extravasor das barragens em relação à variação de nível da bacia do lago da barragem através da medição da régua de nível e da pluviometria local. Desta forma, este trabalho pretende atuar em duas frentes no apoio a operação geotécnica:

1. Apresentar um método de coletar dados das barragens, tratar, processar e avaliar o resultado, conforme critérios apresentados nos objetivos específicos.
2. Utilizar a medição automatizada da variação do nível da bacia do lago e efeitos da pluviometria no mesmo para estimar para os piezômetros da seção crítica da barragem, divididos nas fases de tapete, fundação e aterro, com predições de D+1, D+3 e D+7, que poderão ser utilizados pela geotecnia operacional com o intuito de antever possíveis subidas de nível pela estrutura.

Estas abordagens são efetivamente para prover uma melhor tomada de decisão no apoio à operação de sistemas de barragens. A Figura 1.1 mostra a topologia esquemática do desenho de coleta da instrumentação automatizada de uma barragem, a seta na figura indica de onde parte a requisição dos dados.

Figura 1.1: Arquitetura Básica do Sistema de Coleta de Instrumentação Geotécnica.



Fonte: Autoria própria.

Na Zona de Automação estão localizadas as instrumentações de barragem, onde o fluxo da informação conforme pode ser observado pela figura 1.1 segue a seguinte ordem:

1. Tipicamente a cada fechamento de hora o *middleware*, que é um servidor com software específico responsável por iniciar a comunicação solicitar uma resposta do gateway via protocolo HTTP GET, esta resposta é coletada em um arquivo de dados fornecido em formato *XML*, linguagem de marcação extensível que permite a interpretação do sistema PIMS localizado na intranet da empresa. Por estar localizado na *DMZ*, Zona Desmilitarizada, onde busca-se aumentar a segurança cibernética do sistema, pois evita que da zona de internet/intranet se acesse diretamente a zona de automação, o *middleware* dispara uma requisição do gateway edge para o PIMS.
2. Na zona de automação o gateway edge é um equipamento chamado de *datalogger*, este equipamento armazena as medições coletadas dos instrumentos de campo por um período que pode atingir até 5 anos de armazenamento a depender da configuração da frequência de coleta de dados. Este equipamento também é responsável por enviar um comando de *wake-up*, acordar para a instrumentação, e solicitar seus dados e armazená-los em sua memória *ROM*, memória de leitura.
3. Conectado ao datalogger, o *gateway R2T* é o hardware de rádio dedicado que provê a comunicação com os instrumentos de campo numa frequência de 900MHz.

4. *PIMS*, Sistema de Gerenciamento de Informações de Planta, é o sistema responsável por armazenar toda a informação da instrumentação de em dados brutos para que outros sistemas da camada de apresentação possam consumir os mesmos e transformar para unidade de engenharia e que os usuários possam avaliar a performance da barragem.
5. Na *Zona de Aplicação* são utilizados softwares que são programados para interpretar os dados brutos de modo a serem consumidos de forma amigável pelos usuários finais.

1.2. Objetivos

Propor, desenvolver e avaliar um sistema preditivo para antecipar situações de curto prazo relacionadas com o sensor do tipo piezômetro de corda vibrante em barragens de rejeito. O sistema proposto é multivariável; os dados observados e utilizados nos modelos preditivos são dados históricos de réguas de nível, pluviometria e piezômetros. Investigamos diversos métodos de aprendizado de máquina com o objetivo de encontrar o método que apresenta a maior taxa de acerto nas previsões para D+1, D+3 e D+7. O sistema proposto tem como finalidade o apoio na tomada de decisão por geotécnicos que operam e monitoram barragens de rejeito.

1.2.1. Objetivos Específicos

Os objetivos específicos desse trabalho são:

1. Apresentar um fluxo padronizado para coleta de dados e construção de um sistema preditivo de comportamento de piezômetros localizados em barragens.
2. Investigar métodos de inteligência artificial que apresentem maior taxa de acerto na previsão das janelas de tempo D+1, D+3 e D+7.
3. Discutir sobre o impacto de confiabilidade da previsão das janelas de tempo no sistema preditivo, para as diferentes janelas temporais, considerando diferentes seções da barragem, como tapete, fundação e aterro.

1.3. Organização do Trabalho

Este trabalho tem característica multidisciplinar onde aborda pelo menos duas disciplinas principais:

1. Geotecnia, onde são explorados aspectos básicos de barragens de rejeito na mineração;
2. Aprendizado de Máquina, onde são aplicadas técnicas dessa disciplina para previsão do comportamento da instrumentação piezométrica de barragem.

Desta forma, no Capítulo 1, apresentamos uma contextualização do problema e a motivação para tratar o mesmo e seu objetivo. No Capítulo 2, serão apresentadas as características gerais das barragens e a instrumentação aplicada às mesmas. Já no Capítulo 3, será explorada a revisão bibliográfica referente a utilização de ferramentas de inteligência artificial aplicadas à operação de estruturas geotécnicas, bem como uma breve revisão de algumas técnicas e indicadores de avaliação e confiabilidade. No Capítulo 4 será explorada a metodologia de aquisição, tratamento e processamento dos dados, a justificativa da escolha dos instrumentos associados à esta pesquisa e a aplicação dos modelos de inteligência artificial, na exploração desses dados, além de apresentar alguns resultados preliminares relativos às variações de base de tempo e assertividade dos modelos, bem como o melhor aproximação de previsão para cada uma das variáveis de saída. No Capítulo 5, apresentaremos resultados preliminares e análise das predições geradas. Finalmente no Capítulo 6, conclusão do trabalho, seguida pelo capítulo 7 de sugestões de projetos futuros.

2. O Ambiente de Barragem e os Instrumentos Mais Comuns no Monitoramento

2.1. Tipos de Barragens de Acordo com seus Métodos Construtivos


Nesta seção serão abordados os três métodos construtivos de barragem:

1. Método a jusante;
2. Método a montante;
3. Método ao meio;

2.1.1. Método a Jusante

De acordo com Cardozo *et al.* (2017) uma barragem construída a jusante, significa que nas fases de alteamento da mesma o material de alteamento foi inserido à jusante do rejeito na figura 2.1 é possível verificar o método construtivo:


Figura 2.1: Dique Inicial de uma Barragem de Rejeitos.



Fonte: (CARDOZO *et al.*, 2017).

Na figura 2.2 é possível verificar o mesmo dique já com alteamentos à jusante aplicados sobre o mesmo, a grande vantagem deste método construtivo é a resistência a carga dinâmica que aumenta gradativamente à medida em que outras camadas são adicionadas posteriores ao dique de partida:

Figura 2.2: Alçamento a jusante em uma barragem de rejeitos.




Fonte: (CARDOZO *et al.*, 2017).

2.1.2. Método a Montante

Conforme Cardozo *et al.* (2017) o alçamento à montante utiliza o próprio rejeito adensado, como parte do alçamento que será construído sobre o dique inicial, a figura 2.3 mostra o rejeito adensado à montante da barragem.


Figura 2.3: Dique inicial com rejeito adensado à montante da barragem de rejeitos.



Fonte: (CARDOZO *et al.*, 2017).

Na figura 2.4 é possível verificar que o alçamento foi feito sobre o rejeito adensamento, o grande problema desse método é que tensões são formadas podendo levar a liquefação devido a não consolidação do material utilizado como fundação.

Figura 2.4: Barragem de rejeito com alçamento à montante sobre o rejeito adensado.




Fonte: (CARDOZO *et al.*, 2017).

2.1.3. Método ao Centro

Neste método Cardozo *et al.* (2017) diz que o alteamento é feito tanto à montante quanto à jusante da linha de centro do eixo principal, crescendo à montante sobre o rejeito depositado e o próprio barramento à jusante. Este método visa minimizar as desvantagens dos dois modelos apresentados anteriormente. A figura 2.5 apresenta uma barragem pelo método de linha de centro:

Figura 2.5: Barragem de rejeito com alteamento ao centro.



Fonte: (CARDOZO *et al.*, 2017).

2.2. Piezômetros

Os piezômetros fornecem a medição da carga em pressão no ponto em que são instalados. Para isso calcula-se a carga total naquele no ponto de instalação considerando-se a cota de instalação mais a coluna d'água sobre o piezômetro. Os dois tipos mais comuns em barragens de rejeito são o standpipe ou Casagrande automatizado assim como o piezômetro elétrico de corda vibrante, que é uma variação do piezômetro Casagrande. A carga total em ambos os casos no ponto de instalação é em relação ao nível do mar e pode ser obtida de modo geral através da soma da carga de elevação mais a carga de pressão no ponto de instalação que retorna a cota piezométrica.

Existem diversos tipos de piezômetros na literatura como, mecânico, pneumático, de resistência elétrica e outros, porém neste trabalho somente será abordado os piezômetros tipo Casagrande e Elétrico de corda vibrante, que são comumente utilizados nas barragens que serão utilizadas como objeto de estudo.

2.2.1. Piezômetros Casagrande

É um piezômetro de tubo aberto instalado interno a um corpo de tubo de PVC selado, com diversas ranhuras na ponta. Nesta ponta é encaixado um elemento filtrante que protege o elemento sensor. Segundo Silveira (2006) este piezômetro pode medir até 600m de profundidade e possui uma durabilidade que acompanha toda a vida útil de uma barragem, aproximadamente 50 anos e além de necessitar de pouca manutenção, pois não costuma perder a referência do zero em suas calibrações.

Ainda segundo Silveira (2006) "O tempo requerido para que um standpipe atinja 95% de seu nível de equilíbrio, após uma perturbação no meio" depende do coeficiente de compactação do terreno e do tipo de material aplicado a na barragem durante sua compactação, isto influencia em sua sensibilidade de medição conforme a variabilidade do coeficiente de permeabilidade. A figura 2.6, mostra a tabela de resposta e estabilização de medições piezométricas após perturbação no processo, de acordo com o material aplicado.


Figura 2.6: Tempo de resposta para 95% de equalização.

Tipo de solo k (cm/s)	Areia 10 ⁻³	Silte			Argila		
		10 ⁻⁴	10 ⁻⁵	10 ⁻⁶	10 ⁻⁷	10 ⁻⁸	10 ⁻⁹
Instalação A	8 s	1,3 min	13 min	2,2 h	22 h	9,4 dias	94 dias
Instalação B	12 s	2,0 min	20 min	3,4 h	34 h	14,2 dias	142 dias
Instalação C	17 s	2,9 min	29 min	4,8 h	48 h	20,2 dias	202 dias

Fonte: (SILVEIRA, 2006).

Ideal para medir níveis piezométricos e pressões em solo e rochas porosas, adequado a instalações onde o desfasamento temporal não é crítico pra operação. Abaixo, na Figura 2.7, a ilustração de um piezômetro Casagrande instalado:

Figura 2.7: Piezômetro Casagrande.




Fonte: (DUNNICLIFF, 1993).

Na Figura 2.8 é possível exemplificar a medição de um piezômetro Casagrande na barragem de Itaipu e verificar sua leitura para medição entre as cotas 220,20 e 219,0m. É possível observar que próximo de outubro do ano 2000 houve uma medição bem abaixo da tendência,

isto devido a um fato histórico, pois nesta época os reservatórios brasileiros sofreram com a falta d'água, devido a uma falta de chuva generalizada:

Figura 2.8: Medição de piezômetro Casagrande em relação ao nível do mar.




Fonte: (DE CARVALHO THÁ, 2007).

2.2.2. 2.1.2. Piezômetros Elétricos de Corda Vibrante

Os piezômetros elétricos de corda vibrante, Figura 2.9, se utilizam de um diafragma interno que se utiliza de um elemento sensor tipo corda vibrante, que ao sofrer deformação traduz esta, através de um transdutor para quilograma força por centímetro quadrado, kgf/cm^2 , ou quilo Pascal, kPa. Porém a operação de geotecnia a área converte o valor em metros de coluna d'água, m.c.a, pois a coluna d'água somada a cota de instalação fornece a informação da cota piezométrica no ponto de instalação.

Figura 2.9: Piezômetro de Corda Vibrante.




Fonte: (DUNNICLIFF, 1993).

Estes piezômetros tem a característica de serem mais precisos e sensíveis, porém segundo Silveira (2006) apresentam baixa vida útil em comparação aos piezômetros Casagrande, pois conforme pesquisas tem durabilidade de 30 anos e uma barragem de terra tem tipicamente uma campanha de 50 anos.

Este piezômetro também costuma apresentar mudança nos parâmetros de calibração de seu zero ao longo do tempo caso sofra influência de agentes externos, e também possui um custo de aquisição e instalação mais elevado. Devido ao fato desses instrumentos serem instalados no maciço, não é possível calibrá-los periodicamente, podendo ocasionar perda na precisão.

Na Figura 2.10 é possível verificar a leitura de um piezômetro elétrico de corda vibrante para medição entre as cotas 220,20 e 219,0m entre os anos de 1999 e 2006:

Figura 2.10: Medição de piezômetro elétrico de corda vibrante em relação ao nível do mar.




Fonte: (DE CARVALHO THÁ, 2007).

2.3. Medidor de Nível d'Água

O medidor de nível d'água conhecidos como, INA, informa a cota de superfície freática onde o sensor está instalado. De modo geral é um piezômetro Casagrande sem o selo de bentonita sobre o bulbo. O sensor é inserido no solo através de um encaminhamento feito por tubo de PVC perfurado e envolto por um material filtrante e outro drenante, como pode ser visto na Figura 2.11.

Figura 2.11: Medidor de Nível d'Água.




Fonte: (DUNNICLIFF, 1993).

2.4. Medição de vazão

A medição de vazão de dreno de fundo é uma medição muito importante a ser feita em uma barragem. Isso porque essa medição faz parte do sistema de descarga de fundo, que são estruturas hidráulicas instaladas nas cotas mais baixas do barramento. Seu objetivo é regular a vazão remanescente que passa pelo lençol freático da barragem e busca impedir a criação de fluxo pelo maciço. O sistema de medição do dreno de fundo é um conjunto de tubulações que permitem a saída d'água de forma segura por baixo do aterro da barragem. Conforme mostra a Figura 4.1, onde o dreno de fundo está representado na parte debaixo da Figura.

Figura 2.12: Medição de vazão de dreno de fundo, representado pela tubulação na parte debaixo da Figura.



Fonte: (MASSAD, 2010).

Esta medição é realizada através de um conjunto de calha parshall tipo triangular e medidores ultrassônicos, onde 2.1:


$$Q_v = V/T \quad (2.1)$$

1. Q : É a vazão acumulada em um período T ;
2. V : É o volume medido (litros ou $[m^3]$);

3. T : É o tempo de amostragem (hora);

Os medidores tipo calha parshall são instalados na saída jusante do dreno de fundo onde a calha é uma construção com medidas e volume conhecidos que cria um acumulo do fluído com velocidade conhecida. Desta forma o medidor ultrassônico mede a altura do fluído na calha, calculando a vazão mássica, Na figura 2.13 é possível observar esse esquema de montagem:

Figura 2.13: Medição de vazão mássica na calha parshall instalada á jusante da barragem.



Fonte: (CASTRO, 2008).

2.5. Pluviômetro


De acordo com Medeiros, Carlos Henrique de A. C. (2016), a medição da quantidade de chuva é dada pela altura de água caída e acumulada em uma superfície plana e medida em pontos estratégicos e previamente escolhidos. Para realizar essa medição são utilizados pluviômetros ou pluviógrafos, que são instrumentos que coletam a água precipitada e mostra o acúmulo desta no decorrer do tempo.

Suas grandezas características são:

1. *Altura Pluviométrica*: Medidas realizadas pelos pluviômetros e expressas em mm.
2. *Intensidade da precipitação*: É a relação entre a altura e a duração da precipitação, expressa em mm/h ou mm/min. Neste trabalho extrapolamos as medições em mm/h para mm/d.
3. *Duração*: Período de tempo contado desde o início até o fim da precipitação, expresso em h ou min.

Abaixo na figura 2.14 é possível observar as características do pluviômetro.

Figura 2.14: Esquema de funcionamento de um pluviômetro.



Fonte: (MEDEIROS, CARLOS HENRIQUE DE A. C., 2016).

As medições pluviométricas são importantes pra avaliar o comportamento do nível de água em uma barragem. Conforme afirma Castro (2008), a medição pluviométrica mais a medição dos materiais que entram no reservatório, quando conflitados com a medição de vazão á jusante da barragem e piezômetros, promoverão a diminuição dos erros na interpretação dos dados.

3. Trabalhos Relacionados e Fundamentação Teórica

De acordo com Sasa D. Milic (2022) o aprendizado de máquina ou a ciência de dados consiste em modelos aproximados ou algoritmos utilizados para gerar previsões e sugestões do comportamento do processo que se deseja avaliar, e seus modelos são avaliados em:

1. Aprendizagem de máquina supervisionados: este modelo tipicamente contém dados de um subconjunto que é separado em que 70% desses dados tem respostas conhecidas e os demais 30% fazem parte de um subconjunto que são testados, baseado no primeiro subconjunto e medida sua acurácia para avaliar a qualidade de suas predições. Este modelo pode ser classificado em dois sub títulos, classificação e regressão.
2. Aprendizagem de máquina não supervisionado: Este modelo não utiliza de padrões conhecidos como o anterior. Este modelo clusteriza e analisa subconjunto de dados identificando padrões escondidos.
3. Aprendizagem de máquina semi supervisionado: nesse modelo são separados dados em um subconjunto menor e outro maior. Desta forma são descobertos novos padrões de previsão.
4. Aprendizagem de máquina por reforço: Neste modelo são observados parâmetros comportamentais e ao fazer ajustes nesses parâmetros para uma condição específica, tende a aumentar a possibilidade de um resultado positivo.

3.1. Métodos Supervisionados de Aprendizado de Máquina

Os trabalhos aqui relacionados se integram a esta pesquisa sob a ótica de que estes utilizam-se de ferramentas de inteligência artificial em sistemas geotécnicos para geração de predições do comportamento das estruturas em questão que apesar de não serem barragens, possuem estruturas complexas para o desenvolvimento de modelos matemáticos precisos. Assim, os algoritmos de aprendizagem de máquina entram auxiliando criação de sistemas preditivos.

3.1.1. Redes Neurais Artificiais, ANN

Conforme Ebrahimabadi *et al.* (2015), a Artificial Neural Network (ANN), do português Redes Neurais Artificiais, são a representação das características do cérebro humano biológico expressadas em modelos matemáticos. As ANNs são representações dos neurônios interconectados através de nós que processam a entrada de dados, aplicam um peso a cada entrada e propaga o resultado para a camada posterior. Segundo Satar Mahdevvari (2012) as arquiteturas de uma ANN são determinadas conforme as entradas são conectadas aos nós de um ANN.

De acordo com Yilmaz e Kaynar (2011) uma ANN pode ser utilizada como um substituto direto para técnicas de autocorrelação, regressões multivariáveis, regressão linear, trigonométrica e outras técnicas de análise estatísticas. As ANNs possuem uma habilidade de extrair padrões e detectar tendências de um conjunto de dados muitas vezes complexos e inconsistentes e agir como um especialista provendo projeções a novas situações de interesse, assim a quando se utiliza uma ANN para tratar uma longa base de dados é possível detectar previsões e identificar padrões que não são fáceis de se identificar para profissionais que não são especialistas na área que se está analisando os dados.

As ANNs também podem ser chamadas de Multi Layer Perceptron, Perceptron de Multicamadas, da sigla MLP, e por isso de acordo com Liu *et al.* (2021) o algoritmo aplicado ao MLP pode ser classificador binário de aprendizagem supervisionada que de acordo com a necessidade pode acionar camadas específicas. Sendo necessários três ou mais camadas, que são, uma de entrada e uma de saída e uma ou mais de camadas ocultas. Os nós da camada de entrada são conectados aos nós da camada oculta primária, estas camadas ocultas têm diferentes pesos. Assim, os nós das camadas ocultas recebem o somatório das variáveis de entrada, multiplicados pelos pesos desses nós e os pesos entre os nós são ajustados com o algoritmo de aprendizagem.

Ainda conforme Yilmaz e Kaynar (2011), a MLP transforma “N” entradas em uma saída através de uma função não linear. E a saída desta MLP é determinada pela função de ativação da Equação 3.1 (YILMAZ e KAYNAR, 2011):

$$x_0 = f\left(\sum_h x_h W_{h0}\right) \quad (3.1)$$


Onde: f é a função, x_h é a h-ésima camada oculta, W_{h0} é a interconexão entre a h-ésima camada oculta com a camada de saída do nó. A função de ativação mais utilizada é a função sigmoide, conforme pode ser visto na Equação 3.2 (YILMAZ e KAYNAR, 2011):

$$x_0 = \frac{1}{1 + \exp(-\sum_h x_h W_{h0})} \quad (3.2)$$

Ebrahimabadi *et al.* (2015) dizem que o objetivo do aprendizado supervisionado é minimizar o erro entre a saída da variável objetivo e a saída da rede neural.

Na Figura 3.1 é possível se observar uma arquitetura MLP padrão com duas camadas ocultas.

Figura 3.1: Arquitetura padrão de uma MLP.




Fonte: Autoria própria.

3.1.2. Adaboost

De acordo com Pham *et al.* (2021) o Adaboost (AD) é uma poderosa ferramenta de aprendizagem de máquina desenvolvida por Freund (1996). Este algoritmo se utiliza de algoritmos mais simples como árvores de decisão para se organizar em um modelo robusto de classificador, sendo adequado para problemas de classificação e regressão. A Figura 3.2 ilustra a imagem adaptada da arquitetura do algoritmo Adaboost.

Figura 3.2: Exemplo do processo do Adaboost.




Fonte: Adaptado de Pham *et al.* (2021).

3.1.3. Árvore de Decisão

Conforme Zounemat-Kermani *et al.* (2017), Árvore de Decisão (DT) é uma ferramenta efetiva para classificação de padrões e estimativa de valores alvo. Uma de suas melhores características segundo Pham *et al.* (2021) é o reconhecimento de diferentes relacionamentos entre variáveis, além de serem simples de serem construídas. Em geral são construídas a partir de um nó raiz que vai se dividindo em diferentes seções internas que dependem de diferentes variáveis, e distribuição dos dados e quantidade dos mesmos. Após esta etapa o nós internos são anexados a nós externos, sendo estes recalculados, e dando a formação a novos nós. Novamente segundo Zounemat-Kermani *et al.* (2017) uma desvantagem de uma única árvore é elas são susceptíveis a ruídos nas variáveis e podem apresentar sobreajuste e baixa generalização. Na Figura 3.3 é apresentada a generalização de uma DT.

Figura 3.3: Estrutura Geral de uma Árvore de Decisão.




Fonte: Autoria própria.

3.1.4. Floresta Randômica

A fim de corrigir ou minimizar os efeitos negativos que uma árvore de decisão, Breiman (2001) propôs o modelo *Random Forest* (RF), do inglês Floresta Randômica, um método de aprendizagem baseado na montagem de árvores de decisão que busca os resultados médios destas árvores. Zounemat-Kermani *et al.* (2017), explica que em problemas de regressão uma RF arbitra o número de árvores não treinadas e cria uma combinação estimada de variáveis dependentes através de seus resultados. Uma amostragem aleatória de dados é selecionada e reprocessada repetidamente para formação de novas árvores. Um parâmetro importante é N, quantidade de nós que terá a floresta, que serve para prever a resposta. A Figura 3.4 apresenta uma arquitetura básica de uma RF.

Figura 3.4: Arquitetura típica da Floresta Randômica.



Fonte: Adaptado de Zounemat-Kermani *et al.* (2017).

3.1.5. Regressão Linear

De acordo com Medeiros, Carlos Henrique de A. C. (2016) a regressão linear simples é um algoritmo bem conhecido e utilizado que consiste na obtenção de uma variável dependente que na verdade depende de uma ou mais variáveis independentes, descritas em uma equação linear em que a linha de regressão minimiza os desvios quadrados dos dados reais. Segundo Maroco (2003), a regressão linear é composta por dois coeficientes, o de correlação que explica o quanto duas variáveis são relacionadas e o coeficiente de Pearson que relaciona a covariância entre duas variáveis. A relação $+0,1 \leq R_{xy} \leq +0,5$ é dita uma positiva fraca, a relação $+0,5 \leq R_{xy} \leq +0,8$ é dita positiva moderada e para a relação $+0,8 \leq R_{xy} \leq +1$ é considerada positiva forte. Para as relações negativas é dito que a relação $-0,5 \leq R_{xy} \leq -0,1$ é fraca negativa, a relação $-0,8 \leq R_{xy} \leq -0,5$ é dita negativa moderada e para a relação $-1 \leq R_{xy} \leq -0,8$ é considerada negativa forte. Para valores iguais a 0 é dito que não há correlação.

3.1.6. Gradiente Estocástico Descendente

De acordo com Carlon *et al.* (2022) o algoritmo Gradiente Estocástico Descendente (SGD) busca minimizar a função objetivo baseado na utilização de variáveis randômicas que evitam cair em modelos complexos. SGD busca uma estimativa imparcial do gradiente da função objetivo a ser minimizada. Este algoritmo diminui o esforço computacional e por iteração em comparação com outros métodos de otimização mais simplificados.

3.2. Trabalhos Relacionados sobre Algoritmos Inteligentes na Geotecnia

Wei *et al.* (2021) utilizaram das RNN, Redes Neurais Recorrentes e suas variações e MLP para prever a variação de poro pressão de água em piezômetros em uma encosta na cidade de Hong Kong, China, onde puderam comparar a efetividade dessas duas técnicas frente a técnicas de comparação de erro, RMSE, erro de média quadrática que mostrou que o MLP é aplicável ao problema de predição da medição da poro pressão em relação à quantidade de chuva medida, porém não se apresenta como uma solução robusta. Para o mesmo problema a técnica RNN apresenta uma boa performance na predição dos piezômetros, porém tem sua robustez ligeiramente afetada quando há variações grandes nas medições. Já as variações da RNN, a GRU, unidade de recorrência fechada e LSTM, memória de curto e longo prazo, apresentam grande acurácia na predição da poro pressão e melhoria robustez.

Já Lin *et al.* (2021) utilizaram cinco modelos de inteligência artificial e aprendizagem profunda como BPMN, rede neural de retro propagação, ELM, aprendizagem de máquina extrema, SVM, máquina de suporte de vetor, LSTM e GRU para aplicação na predição do avanço da velocidade de alteração do balanço da pressão de uma massa de terra em escavações de

túneis, que nesse caso foi aplicada em uma escavação localizada em Shenzhen, China, onde verificaram que os modelos de otimização inteligentes foram classificados na seguinte ordem de melhor predição $GRU > LSTM > SVM > ELM > BPMN$, para prever o deslizamento de terra.

Shahin (2016) realiza um apanhado do estado da arte da aplicação de algoritmos de inteligência artificial aplicadas a pilhas, onde é demonstrado que devido à dificuldade de desenvolvimento de modelos matemáticos aderentes à variação da dinâmica física de pilhas e outras estruturas geotécnicas, onde os algoritmos de IA se adaptam rapidamente e com boa assertividade em relação comportamento complexo e muitas vezes com pouco entendidos dessas estruturas.

Baykasoğlu *et al.* (2009), propõe utilizar ANNs, para substituir técnicas de análise estatísticas para prever a liquefação em estruturas geotécnicas. Através da extração de classificação e criação de regras do tipo Se, Então, através de um algoritmo genético que mistura técnicas de ANN e é baseado na otimização por colônia de formigas. Desta forma foi demonstrado que a geração de regras feitas pelo algoritmo possui mais acurácia em relação às regras geradas pelo senso comum.

Outro parâmetro importante na geotecnia é a resistência térmica no solo de uma estrutura geotécnica, de acordo com Erzin *et al.* (2008), devido à dificuldade em desenvolver modelos matemáticos preditivos que definem como a transmissão ou irradiação térmica se comporta em uma estrutura, não tem chegado a grandes resultados devido a ao número elevado de variáveis como tipo de solo, tamanho da distribuição de partículas, outros como densidade e conteúdo das misturas. Para realizar esta aproximação modelos de MLP utilizam-se de diferentes tipos de solo para determinar a resistência térmica dos solos e quando comparado com modelos de laboratório verifica-se que esses modelos se mostram eficientes nessa aproximação.

Já Melchiorre *et al.* (2008), também se utilizaram de modelos de MLP em conjunto com Cluster Analysis (CA), do português Análise de Cluster para modelar relações complexas de modelos não lineares entre movimentos de massa de terra e fatores de susceptibilidade de que influenciam na identificação de áreas instáveis. Neste trabalho a clusterização de dados foi utilizada para tratar a pré-classificação do modelo, enquanto a MLP utilizava-se das médias de seus resultados para separar e classificar casos de deslizamentos de massa e não deslizamento. Este modelo apresentou melhores resultados quando se utiliza de um modelo com uma amostragem mais precisa, resultado da pré-classificação, em relação a um modelo de amostragem randômica para identificação de deslizamento de massa.

Para se determinar a medição de compressibilidade de um solo, é utilizado parâmetro de Coeficiente de Consolidação, importante parâmetro para projetos de fundações civis e estabilidade de taludes, desta forma, Pham *et al.* (2021), utilizam-se de um método híbrido o MPL-BBO, onde BBO, vem de Biogeography-based Optimization, do português Otimização Baseada em Bio-geografia que utilizando-se de 164 amostras de solo de duas estradas diferentes gerou um resultado superior em relação a outros métodos preditivos de identificação do

coeficiente de consolidação quando também comparado a amostras de laboratório apresentando o menor erro quadrático.

Su *et al.* (2018) utilizaram da técnica de Support Vector Machine (SVM), do português Máquina de Suporte de Vetor combinada com outros métodos como reconstrução de espaço, Wavelet Analysis, do português Análise em Pequenas Ondas e Particle Swarm Optimization (PSO), do português Otimização do Enxame de Partículas, para prever a deformação de barragens que possuem diversas não linearidades. Após todo o processamento dos dados históricos observou-se que o modelo SVM apresentou 3 pontos de problema, determinar o vetor de entrada, a seleção da função Kernel que podem ser gaussianas ou polinomiais e os parâmetros de otimização. Este problema foi corrigido combinando a algoritmo de SVM com Morlet wavelet como função Kernel é chamado de WSVM que reconstrói a matriz de estados de deformação de uma barragem fornecendo o inputs pro algoritmo PSO. Adicionalmente o WSVM e a função kernel radial SVM combinadas com o algoritmo PSO melhorado criam o novo modelo de predição de deformação da barragem. Esta última combinação não melhora a acurácia, mas melhora o tempo de processamento computacional e o ótimo local.

Ranković *et al.* (2014) apresentam a utilização de Support Vector Regression (SVR), do português Vetor de Suporte a Regressão para prever o deslocamento tangencial de uma barragem de concreto. Neste trabalho combinaram novamente técnicas de SVM e funções kernel para criar os modelos de SVR. As entradas foram valores do nível de água de à montante e à jusante da barragem baseado em uma série temporal de dados. Os dois modelos SVRs de predição de identificação de deslocamento tangencial, mostraram alta acurácia com 98,47% e 98,82% respectivamente.

4. Proposta de Sistema Preditivo


Para que se consiga desenvolver a metodologia deste trabalho, será utilizada como estrutura alvo uma barragem no Corredor Norte localizada no estado do Pará, no Complexo de Carajás, esta barragem contém um medidor de vazão no extravasor, 34 piezômetros, sendo 11 piezômetros da seção crítica, 7 indicadores de nível, uma régua de nível e uma estação meteorológica, para que se possa buscar evoluir os conceitos de correlação temporal entre sensores na mesma barragem e evolução para um sistema de predição da dinâmica das variáveis.

Este trabalho visa estudar o comportamento e elaborar um piloto de sistema de predição para os piezômetros da seção crítica.

Os critérios de aceitação são que pelo menos 95% das predições sejam menor ou igual a 20cm de variância.

A figura 4.1 descreve todo processo de metodologia deste sistema preditivo:

Figura 4.1: Metodologia de criação dos sistema preditivo.



Fonte: Autoria própria.

4.1. Entendimento do Problema

Barragens tem diversas variáveis que devem ser observadas em sua operação, manutenção e sustentabilidade. De acordo com Zhong *et al.* (2020), que a maioria dos colapsos de barragens são causados por grandes terremotos, fortes chuvas e bloqueios em rios, sendo essas as causas naturais. Porém, as causas de falha por operação, são 89% causadas por galgamento e 10% infiltração/piping. Portanto, esse trabalho visa apoiar a atuação no problema:

1. Infiltração, algumas variáveis de uma estrutura de barragem são difíceis de se obter, como, permeabilidade, absorção do solo, e outras características construtivas. De acordo com Zhen-Ming Shi (2019), o deslocamento de solo ocorre quando a força da elevação da barragem a jusante excede o peso do material flutuante com um rápido aumento do nível de água a montante (bacia da barragem) sendo detectada pela piezometria.

- (a) Como forma de apoio, este trabalho pretende utilizar as informações da régua de nível da bacia, os dados do acumulado diário de chuva da estação meteorológica local e os próprios dados do piezômetro para prever o nível que os piezômetros da seção crítica deverão atingir, que ao comparar com o com os níveis de alarme já conhecidos da estrutura e gerar um alarme antecipado para os operadores do CMG.

4.2. Coleta, tratamento e Processamento de Dados

4.2.1. Coleta dos Dados

A partir do primeiro quadrimestre do ano de 2020 foi iniciado o processo de coleta de automatizada da instrumentação geotécnica aplicada a barragens. Em fevereiro de 2021 foi automatizada a coleta dos dados cumulados diário de chuva da barragem.

Assim, esta solução está integrada da seguinte forma, conforme Figura 1, mostrada anteriormente:

1. A instrumentação de campo se conecta através de uma rede RF de 900MHz proprietária a um *Datalogger* concentrador, localizado no campo;
2. Este *Datalogger*, localizados nas barragens sendo existe um por barragem, recebe e armazena os dados dos diversos instrumentos tais como piezômetros, régua de nível, vazão do extravasor, pluviometria e inclinômetros, neste caso armazenando essas amostras de hora em hora;
3. Através de um ETL, do inglês *Extract Transform Load*, ou seja, um extrator de dados automatizado, esta ferramenta atravessa zonas de rede para coletar de hora em hora os arquivos disponibilizados pelo *Datalogger*, entregando-os e transformando-os em um formato de arquivo aceito pelo PIMS;
4. O PIMS por sua vez, é considerado o repositório de dados das aplicações de barragem sendo a principal fonte de dados, armazenando dados brutos e o *time-stamp* do momento da coleta realizada pelo *Datalogger*. Assim o PIMS além de se tornar o principal repositório para ser consultado por auditorias internas e externas e órgãos nacionais de fiscalização, o mesmo tem a função de servir de principal base de dados para todos os sistemas que apresentam os dados tratados da instrumentação geotécnica aos times de geotecnia para análise e acompanhamento das estruturas;
5. Como principal *software* de monitoramento geotécnico, temos o GEOTEC, um sistema responsável por armazenar e gerir informação como cartas de controle da instrumentação geotécnica, dados de inspeções, cadastros, acompanhamento e gestão de ordens de manutenção e anomalias nos sistemas de monitoramento de barragens.

Desta forma, este trabalho se aproveita de uma massa de dados de coleta automatizada de aproximadamente 1 ano e 6 meses para piezômetros, régua de nível, indicador de nível d'água e pluviometria automatizada. Todos estes instrumentos têm sua coleta sendo realizada de hora em hora.


4.2.2. Tratamento dos Dados

Os dados coletados para tratar o problema de predição do nível de pressão nos piezômetros serão os seguintes, com os seguintes tratamentos:

1. Estação meteorológica:

- (a) Os dados obtidos são coletados a cada 5 minutos em milímetros de chuva acumulada.
 - i. Será realizado um trabalho de integração dos dados para mm/d, milímetros acumulados por dia, sendo os mesmos salvos em uma nova planilha para armazenamento.
 - ii. Na Figura 4.2 é possível verificar o comportamento das chuvas no período de análise.

Figura 4.2: Comportamento do acumulado de chuva no período de fev/2021 à mai/2022 para análise




Fonte: Autoria própria.

2. Nível do reservatório:

- (a) Os dados provenientes da régua de nível, são coletados uma amostra por hora, em m, metros de altura e será utilizado o último valor coletado do dia no regressor.
- (b) Na Figura 4.3 é possível verificar o comportamento da variação do nível do reservatório para o período de análise sem a informação da cota de nível do mesmo.

Figura 4.3: Comportamento da variação do nível do reservatório para o período de fev/2021 à mai/2022 para análise.




Fonte: Autoria própria.

3. Nível dos piezômetros:

- (a) Os piezômetros serão divididos em três categorias de acordo com sua localização na barragem. Isso permitirá verificar onde o modelo é mais aplicável, melhorando assim a assertividade do modelo. Os dados provenientes dos piezômetros, são coletados uma amostra por hora, em mH₂O/H, metro de coluna d'água por hora, e neste caso será utilizado o maior valor coletado do dia pelo regressor.
- (b) Tapete: Nesta seção localizada na base da barragem, espera-se verificar um comportamento que responda aos acumulados de chuva e variações do nível do reservatório, porém seu comportamento dinâmico denota certa previsibilidade nos movimentos como pode ser visto na Figura 4.4, um ponto importante dessa medição é que em caso de variação brusca positiva, pode-se entender que há uma falha no dreno de fundo.


Figura 4.4: Comportamento de um piezômetro localizado no tapete da barragem no período de fev/2021 à mai/2022.



Fonte: Autoria própria.


- (c) Fundação: são piezômetros instalados desde o início da barragem e que fazem parte de seu corpo principal e seu comportamento pode ser observado na Figura 4.5 e na Figura 4.6.

Figura 4.5: Comportamento de um piezômetro de fundação localizado na parte central da barragem no período de abr/2021 à mai/2022.



Fonte: Autoria própria.


Figura 4.6: Comportamento de um piezômetro de fundação localizado na ombreira esquerda da barragem no período de fev/2021 à mai/2022.



Fonte: Autoria própria.

- (d) Aterro: são piezômetros instalados na parte superior da barragem, camada de proteção, normalmente em cotas superiores e mais susceptíveis a ações externas como chuva, transito e demais interferências seu comportamento pode ser observado na Figura 4.7.

Figura 4.7: Comportamento de um piezômetro do aterro localizado na faixa central da barragem no período de abr/2021 à mai/2022.




Fonte: Autoria própria.

Para o desenvolvimento do sistema de predição foi necessário realizar a a integração das datas disponíveis em que se tinha os dados dos piezômetros com os dados disponíveis da estação meteorológica. Por isso, os períodos de amostragem para integração ao regressor serão diferentes em cada um dos casos, pois a amostragem válida dos dados varia, por falha nas coletas de dados automatizada. Assim o período válido para cada um dos conjuntos submetido ao regressor, é apresentado a seguir:

1. Tapete, composto pelo piezômetro T-PZ-001, estação meteorológica EM_mmdia, régua de nível RR-001, e uma sequência de dados de 428 dias consecutivos.
2. Fundação composto pelos piezômetros F-PZFC01_MCA e F-PZFOE01_MCA, estação meteorológica EM_mmdia, régua de nível RR001.
 - (a) Para o conjunto, F-PZFOE01_MCA, EM_mmdia e RR001 a sequência de dados foi de 428 dias consecutivos.
 - (b) Para o conjunto, F-PZFC01_MCA, EM_mmdia e RR001 a sequência de dados foi de 392 dias consecutivos.
3. Aterro, composto pelo piezômetro A-PZ001_MCA, estação meteorológica EM_mmdia, régua de nível RR-001, e uma sequência de dados de 393 dias consecutivos.

Como objetivo este trabalho busca validar um modelo piloto onde possa facilitar o dia a dia da geotecnia operacional de modo que possam trabalhar desde a coleta, transformação e inserção no preditor e posterior análise dos resultados de dados através da verificação de qual algoritmo das diversas ferramentas de aprendizagem de máquina é o mais adequado aos três patamares existentes nas barragens, tapete, fundação e aterro, sob o ponto de vista de prever o comportamento do piezômetro em D+1, D+3 e D+7. Na Figura 4.8 é apresentado o modelo genérico do regressor para se gerar as previsões para a piezometria.

Figura 4.8: Proposta de Regressor para Predição da Pressão Futura da Piezometria da Seção Crítica da Bacia da Barragem.



Fonte: Autoria própria.

Para isso os dados de entrada no regressor coletados da instrumentação foram trabalhados em formato de tabela Excel, xlsx. Para estes dados foram criadas uma série temporal, de D0, dia atual, até D-14, ou seja 14 dias antes do dia atual, conforme Tabela 4.1.

Tabela 4.1: Exemplo da criação de série temporal histórica PASSADO para um instrumento de entrada no regressor.

INST - D0	INST - D-1	INST - D-2	INST - D-3	INST - D-4	INST - D-5	INST - D-6	INST - D-7	INST - D-8	INST - D-9	INST - D-10	INST - D-11	INST - D-12	INST - D-13	INST - D-14
Valor	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	Valor	-	-	-	-	-	-	-	-	-	-	-	-	-
		Valor	-	-	-	-	-	-	-	-	-	-	-	-
			Valor	-	-	-	-	-	-	-	-	-	-	-
				Valor	-	-	-	-	-	-	-	-	-	-
					Valor	-	-	-	-	-	-	-	-	-
						Valor	-	-	-	-	-	-	-	-
							Valor	-	-	-	-	-	-	-
								Valor	-	-	-	-	-	-
									Valor	-	-	-	-	-
										Valor	-	-	-	-
											Valor	-	-	-
												Valor	-	-
													Valor	-
														Valor

Fonte: Autoria própria.

Na mesma tabela de arquivo que deve ser carregada no regressor é preciso criar os valores base de saída, outra série temporal, agora prevendo o valor do instrumento no futuro a ser comparado com as saídas dos modelos de predição. Para os dados que deseja prever seu comportamento futuro criam-se então seus pares de D0, dia atual até D+7, dia atual mais sete dias. Conforme pode ser observado na Tabela 4.2:

Tabela 4.2: Exemplo da criação de série temporal histórica FUTURO para um instrumento de entrada no regressor.

INST - D0	INST - D+1	INST - D+2	INST - D+3	INST - D+4	INST - D+5	INST - D+6	INST - D+7
Valor 1	Valor 2	Valor 3	Valor 4	Valor 5	Valor 6	Valor 7	Valor 8
Valor 2	Valor 3	Valor 4	Valor 5	Valor 6	Valor 7	Valor 8	-
Valor 3	Valor 4	Valor 5	Valor 6	Valor 7	Valor 8	-	-
Valor 4	Valor 5	Valor 6	Valor 7	Valor 8	-	-	-
Valor 5	Valor 6	Valor 7	Valor 8	Valor	-	-	-
Valor 6	Valor 7	Valor 8	-	-	-	-	-
Valor 7	Valor 8	-	-	-	-	-	-
Valor 8	-	-	-	-	-	-	-

Fonte: Autoria própria.

4.2.3. Processamento de Dados


Uma vez que as planilhas são tratadas, ou seja, concluído o pré-tratamento, as mesmas são carregadas no *software* de mineração de dados e aprendizado de máquina, chamado Orange

Canvas versão 3.29.3. Para o trabalho de processamento dos dados, ao se utilizar o *software* Orange Canvas foi possível realizar a predição através de 6 algoritmos de aprendizagem de máquina, robustecendo a análise, esses algoritmos são:

1. Floresta Randômica, RF
2. Adaboost, AD
3. Redes Neurais, ANN
4. Regressão Linear, LN
5. Árvore de Decisão, DT
6. Gradiente Estocástico Descendente, SGD

A Figura 4.9, que é um *print* da execução do tratamento de dados, mostra a arquitetura utilizada para treino, classificação e entrega dos dados, em que o “*Target*”, alvo, é saída desejada que está contida na “Data Table”, Tabela de Dados.

Figura 4.9: Arquitetura de testes e validação do modelo de predição dos valores da piezometria.



Fonte: Autoria própria.

Uma vez submetido ao processamento de dados a Tabela de Dados é primeiramente exportada para um arquivo de texto, “.dat”, para que os dados que contenham casas decimais em formato americano separado por ponto, seja convertido para o formato brasileiro com os

dados separados por vírgula. Após esta conversão este arquivo de texto é importado para o Excel para que sejam trabalhados os aspectos de análise e comparação dos resultados obtidos.

4.3. Investigação de Algoritmos de Inteligência Artificial

Conforme apresentado na Seção 4.2.3, os algoritmos disponíveis para processamento dos dados no *software* Orange Canvas versão 3.29.3 foram apresentados com mais detalhes no capítulo 3. No capítulo 5 serão apresentadas análises em cima desses algoritmos e os resultados das predições feitas a partir desses.

4.4. Investigação do Impacto da Confiabilidade na Predição

Nesta seção serão abordados os critérios de avaliação de desempenho dos algoritmos utilizados para a predição da piezometria. Os indicadores de desempenho aqui escolhidos são comumente utilizados em modelos de aprendizagem de máquina e apoiarão na avaliação da acurácia e precisão dos modelos e seleção dos obtiverem melhor resposta.

4.4.1. Coeficiente de Determinação

Conforme Khan *et al.* (2022) o coeficiente de determinação R^2 indica o quão aderente a predição está em relação a média de variação da variável real. Seu valor varia de 0 a 1 e quanto mais próximo de 1, maior sua confiança em seguir os movimentos médios de tendência da variável. A Equação 4.1 representa sua proposta.

$$R^2 = 1 - \frac{\sum (t_i - \hat{t}_l)^2}{(t_i - \hat{t}_l)^2} \quad (4.1)$$

Onde t_i é o valor atual cumulativo de casos confirmados e $\hat{t}_l$ é o valor predito cumulativo de casos confirmados.

4.4.2. Raiz Quadrada do Erro Médio

Raiz Quadrada do Erro Médio (RMSE) é explicado por Khan *et al.* (2022) como o indicador que verifica o desvio residual em relação a linha média padrão da variável ao longo do tempo, ou seja é um indicador que busca mostrar *outliers* na predição. E a Equação 4.2 mostra como o indicador é calculado.

$$RMSE = \sqrt{\frac{1}{k} \sum_{m=1}^k (a_m - \hat{a}_m)^2} \quad (4.2)$$

Onde “k” é o número de observações, a_m é o valor observado e $\hat{a}_m$ é o valor predito.

4.4.3. Erro Médio Absoluto

O Erro Médio Absoluto (MAE), de acordo com Khan *et al.* (2022) mede o erro normal, diferença, entre a variável predita e o valor real, porém normalizando sempre o valor positivo, para que o somatório da função não se desloque para zero. O valor de MAE é calculado pela Equação 4.4:

$$MAE = \frac{1}{p} \sum_{q=1}^p |r_q - r| \quad (4.3)$$

Onde, “p” representa o número de erros e $|r_q - r|$ denota o erro absoluto.

4.4.4. Erro Médio Quadrático

Conforme Khan *et al.* (2022) o Erro Médio Quadrático (MSE) de um estimador qualitativo entre o valor predito e valor real. Seus valores são confiáveis se positivo e mais próximo de zero. MSE é calculado conforme a Equação 4.4:

$$MSE = \frac{1}{Z} \sum_{s=1}^Z (y_s - \hat{y}_s)^2 \quad (4.4)$$

Onde, “Z” é o número de pontos de dados, y_s representa os valores observados e $\hat{y}_s$ representa os valores preditos.

5. Resultados e Discussões


5.1. Investigação dos Algoritmos de Inteligência Artificial

Nesta seção serão analisados comportamentos dos piezômetros e as previsões geradas para d+1, D+1 e D+7, separados pelas seções de barragem, tapete, fundação e aterro.

5.1.1. Análise Algoritmos para o Piezômetro T-PZ-001, previsão do Tapete para 1, 3 e 7 dias á frente em relação ao dia atual

Primeiramente será apresentado o comportamento do piezômetro localizado nesta seção, será apresentado em um gráfico do tipo boxplot que mostra a concentração de seus dados, esta análise de sensibilidade, mostra que a pouca dispersão dos dados que os mesmos estão concentrados no ponto -0,05mca. O comportamento de sua tendência já pôde ser observado na Figura 5.1.

Figura 5.1: Análise de sensibilidade do piezômetro localizado no tapete da barragem.




Fonte: Autoria própria.

Para todos os casos quando aplicado o modelo apresentado na seção 4.1.4, é possível verificar pelos gráficos de sensibilidade na Figura 5.2, Figura 5.3 e Figura 5.4, que o algoritmo Adaboost forneceu melhor desempenho em relação ao MAE que representa um melhor desvio médio entre o predito e observado com 100% dos dados preditos abaixo de 20cm de precisão, o que garante uma boa assertividade na predição, porém é possível verificar que a dispersão


ou perda de acurácia a medida que vai aumentando a medida que a janela de predição sai de D+1 para D+7. Apesar disso para o caso de predição para o nível de tapete em barragens de rejeito os algoritmos seleccionados apresentam boa assertividade e confiabilidade para auxiliar a geotecnia operacional na análise de desempenho da estrutura.

Figura 5.2: Análise de sensibilidade da predição T-PZ-001 previsão para um dia à frente em relação ao dia atual de processamento.




Fonte: Autoria própria.

Figura 5.3: Análise de sensibilidade da predição T-PZ-001 previsão para três dias à frente em relação ao dia atual de processamento.



Fonte: Autoria própria.


Figura 5.4: Análise de sensibilidade da predição T-PZ-001 previsão para sete dias à frente em relação ao dia atual de processamento.



Fonte: Autoria própria.


O modelo apresentado na seção 4.1.4 será aplicado novamente, agora para o piezômetro de fundação localizado na seção central, F-PZFC01. Ao se observar o gráfico da Figura 5.6, verifica-se que o algoritmo Adaboost teve uma melhor concentração de 98% dos dados abaixo de 20cm de variância. Já no gráfico de sensibilidade 12 da Figura 5.5, são demonstrados os desempenhos dos algoritmos para a previsão D+1, nele é possível observar que os algoritmos Floresta Randômica e Adaboost tiveram desempenho parecido com ligeira vantagem para o Adaboost, que consegue agrupar maior quantidade de predições dentro da variância de 20cm. Quando se observa o gráfico da Figura 5.7 é possível verificar o desempenho dos algoritmos para a predição D+7, fazendo uma análise de sensibilidade as predições da Floresta Randômica apresentou 93,8% em até 20cm de precisão e 95,15% para o Adaboost, sendo este novamente o algoritmo que apresentou melhor desempenho.

Figura 5.5: Análise de sensibilidade da predição F-PZFC-001 previsão para um dia à frente em relação ao dia atual de processamento.




Fonte: Autoria própria.

Figura 5.6: Análise de sensibilidade da predição F-PZFC-001 previsão para três dias à frente em relação ao dia atual de processamento.



Fonte: Autoria própria.

Figura 5.7: Análise de sensibilidade da predição F-PZFC-001 previsão para sete dias à frente em relação ao dia atual de processamento.




Fonte: Autoria própria.

5.1.2. Análise de Algoritmos Para o Piezômetro F-PZFOE01_MCA, Fundação Ombreira Esquerda D+1

Este piezômetro está localizado na ombreira esquerda da barragem e tem uma possível compactação e possivelmente diferente de solo se comparado ao piezômetro F-PZFC-001. Conforme pode ser avaliado pelo gráfico na Figura 5.8, as previsões para D+1 o algoritmo Adaboost foi ligeiramente melhor que a Floresta Randômica e a Regressão Linear. Porém, somente 83,3% das amostras estão abaixo de 20cm de variância atendem a este critério. Por isso, nesta seção não serão avaliadas as previsões de D+3 e D+7. Abaixo o Gráfico de sensibilidade 14 que corrobora com a avaliação citada.

Figura 5.8: Análise de sensibilidade da predição F-PZOE-001 previsão para um dia à frente em relação ao dia atual de processamento.




Fonte: Autoria própria.

5.1.3. 2.3.4. Análise algoritmos para o piezômetro A-PZ-001_MCA, Aterro D+1, D_3 e D+7

Nesta seção será avaliado o piezômetro de aterro A-PZ-001 será aplicado ao modelo apresentado na seção 4.1.4 será aplicado novamente. A partir do gráfico 15 é possível verificar que os algoritmos de Regressão Linear e Adaboost apresentaram desempenho extremamente similares e um alto fit dos modelos de predição em relação à variável real. Como é possível verificar pelo gráfico da Figura 5.9 existe a presença de *outliers* e uma maior concentração de previsões acima de 20cm, apesar de 96,1% das previsões estarem abaixo desta faixa, isso pode

criar uma incerteza maior na predição, conforme pode ser verificado pelo espalhamento das predições.


Figura 5.9: Análise de sensibilidade da predição A-PZ-001 previsão para um dia à frente em relação ao dia atual de processamento.



Fonte: Autoria própria.

Observa-se pelo gráfico da Figura 5.10 que o algoritmo Adaboost se diferencia dos demais em nível de desempenho que conseguiu uma concentração de 90,3% das predições abaixo de 20cm.


Figura 5.10: Análise de sensibilidade da predição A-PZ-001 previsão para três dias à frente em relação ao dia atual de processamento.



Fonte: Autoria própria.

Avaliando o desempenho de D+7 para o A-PZ-001 na Figura 5.11, novamente o algoritmo Adaboost se destaca sob os outros, porém 77% das predições ficaram abaixo dos 20cm, o que invalida a predição sob a ótica dos critérios estabelecidos.

Figura 5.11: Análise de sensibilidade da predição A-PZ-001 previsão para sete dias à frente em relação ao dia atual de processamento.



Fonte: Autoria própria.

5.2. Investigação do Impacto de Confiabilidade da Predição

5.2.1. Análise Confiabilidade para o Piezômetro T-PZ-001, Tapete D+1, D+3 e D+7

Aplicando o modelo apresentado na seção 4.1.4 pode-se verificar pela Tabela 5.1 é possível verificar que para esse caso D+1 o método Adaboost apresentou os melhores indicadores para os indicadores RMSE, MAE e R^2 . Verificando a Tabela 5.2 6, caso D+3, o algoritmo Adaboost teve desempenho ligeiramente superior a Floresta Randômica, os dois métodos apresentaram uma alta concentração de dados em torno do valor 0,01cm de variação e mantiveram 100% de seus dados abaixo da variação de 0,2cm. Quando observada a Tabela 5.3 8 que trás os parâmetros de avaliação para o caso D+7, novamente os algoritmos Adaboost e Floresta Randômica tiveram os melhores resultados, entretanto o parâmetro R^2 diminui substancialmente se comparado com D+1 e D+3, portanto apresenta maior variância dos valores preditos, em outras palavras apresentou menor assertividade na predição, não apresentando uma confiabilidade adequada para ser utilizado como apoio na antecipação da tendência de comportamento desse piezômetro .

Tabela 5.1: Avaliação dos resultados dos algoritmos X critérios de avaliação, T-PZ-001 D+1.

	MSE	MSAE	MAE	R2
DT	0,00033	0,01806	0,01165	0,82411
SGD	0,00032	0,01778	0,01244	0,82946
RF	0,00020	0,01431	0,00932	0,88953
ANN	0,00043	0,02063	0,01333	0,77043
LN	0,00146	0,03826	0,02709	0,21015
AD	0,00019	0,01395	0,00887	0,89507

Fonte: Autoria própria.

Tabela 5.2: Avaliação dos resultados dos algoritmos X critérios de avaliação, T-PZ-001 D+3.

	MSE	MSAE	MAE	R2
DT	0,00051	0,02259	0,01514	0,73004
SGD	0,00074	0,02727	0,01839	0,60654
RF	0,00037	0,01931	0,01289	0,80270
ANN	0,00086	0,02939	0,01834	0,54298
LN	0,00154	0,03920	0,02789	0,18677
AD	0,00032	0,01791	0,01153	0,83024

Fonte: Autoria própria.

Tabela 5.3: Avaliação dos resultados dos algoritmos X critérios de avaliação, T-PZ-001 D+7.

	MSE	MSAE	MAE	R2
DT	0,00094	0,03058	0,01795	0,50465
SGD	0,00192	0,04387	0,02890	-0,0191
RF	0,00064	0,02527	0,01487	0,66173
ANN	0,00115	0,03387	0,02174	0,39246
LN	0,00154	0,03924	0,02801	0,18454
AD	0,00058	0,02403	0,01350	0,69415

Fonte: Autoria própria.

5.2.2. Análise Confiabilidade para o Piezômetro F-PZFC01 MCA, Fundação Central D+1, D+3 e D+7

Pode-se verificar pela Tabela 5.4 que para esse caso D+1 que tem valores de RMSE serem sempre maiores que os valores de MAE, significa que os dados possuem alta acurácia e poucos ou nenhum outlier. Ainda verificando a tabela 10 é possível verificar que os desempenhos dos algoritmos Adaboost e Floresta Randômica apresentaram maior R^2 , sendo o algoritmo adaboost ligeiramente superior e que 98% das predições estiveram abaixo de 20 cm de precisão.

Tabela 5.4: Avaliação dos resultados dos algoritmos X critérios de avaliação, F-PZFC-001 D+1.

	MSE	MSAE	MAE	R2
DT	0,00522	0,07223	0,03509	0,96910
SGD	0,01121	0,10586	0,06831	0,93361
RF	0,00380	0,06162	0,02955	0,97751
ANN	0,00555	0,07447	0,04821	0,96715
LN	0,00422	0,06495	0,03489	0,97501
AD	0,00364	0,06034	0,03062	0,97843

Fonte: Autoria própria.

Na Tabela 5.5 demonstra que os desempenhos dos algoritmos para a previsão D+3. Pelos valores apresentados é possível afirmar novamente que pela relação RMSE e MAE que as previsões não apresentaram altas quantidades de outliers e que pelo valor de R^2 o algoritmo com melhor classificação foi o Floresta Randômica que apresentou 96,4% de suas previsões abaixo de 20cm de precisão, porém o algoritmo Adaboost apresentou 97,4% de suas previsões abaixo de 20cm de precisão, portanto teve um desempenho superior.

Tabela 5.5: Avaliação dos resultados dos algoritmos X critérios de avaliação, F-PZFC-001 D+3.

	MSE	MSAE	MAE	R2
DT	0,01052	0,10257	0,05572	0,93679
SGD	0,01667	0,12911	0,08799	0,89986
RF	0,00668	0,08173	0,04412	0,95987
ANN	0,00875	0,09352	0,06162	0,94746
LN	0,00958	0,09786	0,05680	0,94247
AD	0,00723	0,08501	0,04605	0,95658

Fonte: Autoria própria.

Ao se verificar a Tabela 5.6 e a Figura 5.7 é possível verificar o desempenho dos algoritmos para a previsão D+7. Ao avaliar os dados na tabela que os algoritmos Adaboost e Floresta Randômica mostraram o MSE baixo e também RMSE maior que o MAE o que pode ser interpretado como a existência de poucos outliers. Outro ponto é que ainda apresentam um bom valor para a métrica de R^2 95% em que as previsões da Floresta Randômica apresentou 93,8% em até 20cm de precisão e 95,15% para o Adaboost.

Tabela 5.6: Avaliação dos resultados dos algoritmos X critérios de avaliação, F-PZFC-001 D+7.

	MSE	MSAE	MAE	R2
DT	0,01312	0,11456	0,06060	0,91884
SGD	0,02273	0,15076	0,10459	0,85944
RF	0,00802	0,08953	0,05148	0,95043
ANN	0,01193	0,10922	0,07738	0,92623
LN	0,01642	0,12816	0,08362	0,89842
AD	0,00706	0,08405	0,04944	0,95631

Fonte: Autoria própria.

5.2.3. Análise Confiabilidade para o Piezômetro F-PZFOE01_MCA, Fundação Ombreira Esquerda D+1, D+3 e D+7

Conforme pode ser visto pela Tabela 5.7 seus valores de RMSE são relativamente altos e isso indica maiores valores e quantidades de outliers em sua medição que é acompanhada por um MAE elevado e um fator R^2 já próximo do valor inferior estabelecido neste trabalho. Quando se avalia efetivamente quanto das amostras estão abaixo de 20cm de variância, somente 83,3% dos valores atendem a este critério já em D+1 utilizando o algoritmo Adaboost que foi ligeiramente melhor que a Floresta Randômica e a Regressão Linear. Por isso, nesta seção não serão avaliadas as previsões de D+3 e D+7. Abaixo seguem a Tabela 5.7 que corrobora com a avaliação citada.

Tabela 5.7: Avaliação dos resultados dos algoritmos X critérios de avaliação, F-PZFOE-001 D+1.

	MSE	MSAE	MAE	R2
DT	0,09662	0,31084	0,14964	0,94315
SGD	0,08014	0,28308	0,16687	0,95285
RF	0,06100	0,24698	0,12086	0,96411
ANN	0,06526	0,25545	0,14327	0,96161
LN	0,05603	0,23670	0,12216	0,96704
AD	0,06688	0,25861	0,12235	0,96065

Fonte: Autoria própria.

5.2.4. Análise Confiabilidade para o Piezômetro A-PZ-001_MCA, Aterro D+1, D+3 e D+7

Nesta seção será avaliado o piezômetro de aterro A-PZ-001 será aplicado ao modelo apresentado na seção 4.1.4 será aplicado novamente. Conforme Tabela 5.8 é possível verificar que os algoritmos de Regressão Linear e Adaboost apresentaram desempenho extremamente

similares, seu MSE possui valores baixos o que explica poucos outliers na predição, assim como RMSE muito maior que os valores de MAE confirmando a afirmação anterior. Com R^2 próximo de 1 é possível afirmar um alto fit dos modelos de predição em relação à variável real. Com um MAE relativamente alto, existe a presença de outliers, e uma alta concentração de predições acima de 20cm, apesar de 96,1% das predições estarem abaixo desta faixa, podendo criar uma incerteza maior na predição.

Tabela 5.8: Avaliação dos resultados dos algoritmos X critérios de avaliação, A-PZ-001 D+1.

	MSE	MSAE	MAE	R2
DT	0,01771	0,13307	0,08019	0,98427
SGD	0,02468	0,15710	0,09306	0,97807
RF	0,01401	0,11836	0,06427	0,98755
ANN	0,02236	0,14954	0,09359	0,98013
LN	0,01144	0,10694	0,05657	0,98984
AD	0,01244	0,11152	0,06461	0,98895

Fonte: Autoria própria.

Pela Tabela 5.9 observa-se que o algoritmo Adaboost se diferencia dos demais em nível de desempenho com um valor de MAE ainda relativamente baixo e com o RMSE ligeiramente mais alto evidenciando poucos outliers e uma concentração de 90,3% das predições abaixo de 20cm, o que tende a invalidar esta predição.

Tabela 5.9: Avaliação dos resultados dos algoritmos X critérios de avaliação, A-PZ-001 D+3.

	MSE	MSAE	MAE	R2
DT	0,04905	0,22148	0,13072	0,95544
SGD	0,08981	0,29968	0,20811	0,91842
RF	0,03631	0,19056	0,11244	0,96701
ANN	0,05728	0,23934	0,15630	0,94797
LN	0,05002	0,22365	0,13854	0,95457
AD	0,02526	0,15893	0,09359	0,97796

Fonte: Autoria própria.

Avaliando o desempenho de D+7 para o A-PZ-001, novamente o algoritmo Adaboost se destaca sob os outros, entretanto os altos valores de MAE demonstra que há uma grande dispersão nos valores preditos, como pode ser observado na Tabela 5.10, onde 77% das predições ficaram abaixo dos 20cm.

Tabela 5.10: Avaliação dos resultados dos algoritmos X critérios de avaliação, A-PZ-001 D+7.

	MSE	MSAE	MAE	R2
DT	0,05967	0,24428	0,13433	0,94414
SGD	0,13698	0,37011	0,25960	0,87176
RF	0,04195	0,20482	0,12630	0,96073
ANN	0,07769	0,27873	0,18657	0,92727
LN	0,09460	0,30758	0,21346	0,91144
AD	0,02658	0,16305	0,10494	0,97511

Fonte: Autoria própria.

5.3. Análise dos resultados frente a operação de barragens

Após todo o apanhado realizado no capítulo 5, foi possível verificar que para funcionar corretamente um sistema preditivo para a piezometria necessitará da avaliação de um profissional de geotecnia para validar o quão assertivo é o modelo para cada fase da barragem.

Entretanto, as predições se mostraram adaptáveis e promissoras de serem aplicadas a qualquer tipo de barragem de rejeito de minério. Possui potencial para se integrar aos procedimentos de monitoramento e emergência de barragens, gerando predições antecipadas de possíveis entradas em nível de emergência por instrumento. Uma vez que essa integração seja desenvolvida esta ferramenta se torna poderosa nos períodos de chuva, pois se relaciona diretamente com o dia a dia de operação de barragens.

Outro aspecto importante é que foi possível verificar que quanto mais profundo os piezômetros, ou seja os de fundação e tapete, os mesmos são menos susceptíveis às intempéries e ficam mais diretamente correlacionados a variação do nível do reservatório e a boa capacidade de drenagem da barragem, assim essa ferramenta pode se tornar um forte aliado na predição de falhas construtivas mais à base da estrutura.

Verificou-se também que na camada de aterro que é mais superficial que as demais, sofre influência de intempéries faz com que a dinâmica de variação com a chuva e menos com as variações acumuladas na solo compactado o que fez com que predições com visões mais longas são mais difíceis de se realizar, não sendo então tão assertivas quanto as demais.

6. Conclusão

Este trabalho se propôs a estruturar um padrão criação de um processo de tratamento de dados e geração de predição de dados da piezometria básica em barragens de rejeito, que possa ser utilizado por qualquer profissional de geotecnia de modo manual, sob este aspecto o projeto foi bem sucedido.

Outro ponto importante foi realizar a avaliação dos algoritmos mais adequados para a predição para D+1, D+3 e D+7 nas fases de tapete, fundação e aterro em barragens de rejeito para piezômetros de corda vibrante. Conforme pôde ser avaliado no capítulo 5, o algoritmo Adaboost se destacou sendo superior em praticamente todos as predições realizadas, se mantendo muito competitivo mesmo quando perdeu por diferença mínima para o algoritmo Floresta Randômica e Regressão Linear, se mostrando altamente confiável ao seguir a tendência, mesmo que sazonal, da piezometria, conforme o parâmetro R^2 demonstrou, e buscando minimizar os efeitos de outliers e buscando reduzir a variância das predições.

A última questão que esse trabalho se propõe a resolver, é demonstrar que ao se separar a barragem por fases é possível confirmar gerar predições confiáveis sobre a piezometria. Assim, foi possível observar que para o parâmetro de considerar como válidas a concentração 95% da predição com variação de até 20cm, foi possível observar que para as fases de tapete e fundação para D+1, D+3 e D+7 o trabalho obteve desempenho adequado e, portanto, sucesso. Porém, para as predições na camada de aterro, somente a predição de D+1 obteve sucesso, e, portanto, para D+3 e D+7, não foi possível obter sucesso na predição, pois os desempenhos dos algoritmos degradaram e não atenderam ao objetivo.

De um modo amplo o trabalho atendeu aos objetivos propostos, pois expôs uma forma padrão de realizar predições piezométricas, utilizando um conjunto mínimo de entradas, assim como em quais fases da barragem foi possível aplicar o método e se obter bons resultados.

7. Trabalhos Futuros

Como trabalhos futuros pode-se destacar como continuidade desse trabalho:

1. Criar um algoritmo de coleta dos dados diários e automatizar o processo de tratamento, processamento, avaliação e exposição das previsões, de modo a evitar erros na manipulação e padronizar todo o processo.
2. Explorar a otimização do algoritmo Adaboost para na previsão da piezometria e outras instrumentações de barragem.
3. Buscar técnicas que possam melhorar a previsão para os piezômetros da camada de aterro que são mais suscetíveis a interferências pluviométricas e diferentes compactações do solo.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES), Código de Financiamento 001; do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); e da Vale SA.

Referências Bibliográficas

- BAYKASOĞLU, A., ÇEVİK, A., ÖZBAKIR, L., et al.. “Generating prediction rules for liquefaction through data mining”, *Expert Systems with Applications*, v. 36, n. 10, pp. 12491–12499, 2009. ISSN: 0957-4174. doi: <https://doi.org/10.1016/j.eswa.2009.04.033>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S095741740900373X>>.
- BREIMAN, L. “Random Forests”, *Machine Learning*, v. 45, n. 1, pp. 5–32, Oct 2001. ISSN: 1573-0565. doi: 10.1023/A:1010933404324. Disponível em: <<https://doi.org/10.1023/A:1010933404324>>.
- CARDOZO, F. A. C., PIMENTA, M. M., ZINGANO, A. C. “MÉTODOS CONSTRUTIVOS DE BARRAGENS DE REJEITOS DE MINERAÇÃO – UMA REVISÃO”, *HOLoS*, v. 8, pp. 77–85, maio 2017. doi: 10.15628/holos.2016.5367. Disponível em: <<https://www2.ifrn.edu.br/ojs/index.php/HOLoS/article/view/5367>>.
- CARLON, A. G., KROETZ, H. M., TORII, A. J., et al.. “Risk optimization using the Chernoff bound and stochastic gradient descent”, *Reliability Engineering System Safety*, v. 223, pp. 108512, 2022. ISSN: 0951-8320. doi: <https://doi.org/10.1016/j.ress.2022.108512>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0951832022001703>>.
- CASTRO, L. V. P. D. *Avaliação do comportamento do nível d’água em barragem de contenção de rejeito alteada a montante*. Tese de Mestrado, São Paulo : Escola Politécnica, Universidade de São Paulo., 2008.
- DE CARVALHO THÁ, P. *Estudo das Condições de Fluxo pela Barragem de Terra da Margem Esquerda de Itaipu*. Tese de Doutorado, PUC-Rio, 2007.
- DUNNICLIFF, J. *Geotechnical instrumentation for monitoring field performance*. John Wiley & Sons, 1993.
- EBRAHIMABADI, A., AZIMIPOUR, M., BAHREINI, A. “Prediction of roadheaders’ performance using artificial neural network approaches (MLP and KOSFM)”,

- Journal of Rock Mechanics and Geotechnical Engineering*, v. 7, n. 5, pp. 573–583, 2015. ISSN: 1674-7755. doi: <https://doi.org/10.1016/j.jrmge.2015.06.008>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1674775515000839>>.
- ERZIN, Y., RAO, B. H., SINGH, D. “Artificial neural network models for predicting soil thermal resistivity”, *International Journal of Thermal Sciences*, v. 47, n. 10, pp. 1347–1358, 2008. ISSN: 1290-0729. doi: <https://doi.org/10.1016/j.ijthermalsci.2007.11.001>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1290072907002360>>.
- KHAN, M. A., KHAN, R., ALGARNI, F., et al.. “Performance evaluation of regression models for COVID-19: A statistical and predictive perspective”, *Ain Shams Engineering Journal*, v. 13, n. 2, pp. 101574, 2022. ISSN: 2090-4479. doi: <https://doi.org/10.1016/j.asej.2021.08.016>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2090447921003385>>.
- LIN, S.-S., SHEN, S.-L., ZHANG, N., et al.. “Modelling the performance of EPB shield tunnelling using machine and deep learning algorithms”, *Geoscience Frontiers*, v. 12, n. 5, pp. 101177, 2021. ISSN: 1674-9871. doi: <https://doi.org/10.1016/j.gsf.2021.101177>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1674987121000414>>.
- LIU, Z., GILBERT, G., CEPEDA, J. M., et al.. “Modelling of shallow landslides with machine learning algorithms”, *Geoscience Frontiers*, v. 12, n. 1, pp. 385–393, 2021. ISSN: 1674-9871. doi: <https://doi.org/10.1016/j.gsf.2020.04.014>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S167498712030116X>>.
- MASSAD, F. *Obras de terra: curso básico de geotecnia*. Oficina de textos, 2010.
- MEDEIROS, CARLOS HENRIQUE DE A. C. “Curso Segurança em Barragens: Unidade 5, Módulo 1”. Disponível em: <http://dspace.agencia.gov.br:8080/conhecerhana/2179>. Acesso em 12/11/2022, 2016.
- MELCHIORRE, C., MATTEUCCI, M., AZZONI, A., et al.. “Artificial neural networks and cluster analysis in landslide susceptibility zonation”, *Geomorphology*, v. 94, n. 3, pp. 379–400, 2008. ISSN: 0169-555X. doi: <https://doi.org/10.1016/j.geomorph.2006.10.035>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169555X07002747>>. GIS technology and models for assessing landslide hazard and risk.

- PHAM, B. T., NGUYEN, M. D., NGUYEN-THOI, T., et al.. “A novel approach for classification of soils based on laboratory tests using Adaboost, Tree and ANN modeling”, *Transportation Geotechnics*, v. 27, pp. 100508, 2021. ISSN: 2214-3912. doi: <https://doi.org/10.1016/j.trgeo.2020.100508>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214391220303962>>.
- RANKOVIĆ, V., GRUJOVIĆ, N., DIVAC, D., et al.. “Development of support vector regression identification model for prediction of dam structural behaviour”, *Structural Safety*, v. 48, pp. 33–39, 2014. ISSN: 0167-4730. doi: <https://doi.org/10.1016/j.strusafe.2014.02.004>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167473014000174>>.
- SASA D. MILIC, ŽELJKO ĐUROVIC, M. D. S. “Data science and machine learning in the IIoT concepts of power plants”, *International Journal of Electrical Power Energy Systems*, v. 145, 2022. ISSN: 108711. doi: <https://doi.org/10.1016/j.ijepes.2022.108711>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061522007074>>.
- SATAR MAHDEVARI, S. R. T. “Prediction of tunnel convergence using Artificial Neural Networks”, *Tunnelling and Underground Space Technology*, v. 28, pp. 218–228, 2012. ISSN: 0886-7798. doi: <https://doi.org/10.1016/j.tust.2011.11.002>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0886779811001453>>.
- SHAHIN, M. A. “State-of-the-art review of some artificial intelligence applications in pile foundations”, *Geoscience Frontiers*, v. 7, n. 1, pp. 33–44, 2016. ISSN: 1674-9871. doi: <https://doi.org/10.1016/j.gsf.2014.10.002>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1674987114001327>>. Special Issue: Progress of Machine Learning in Geosciences.
- SILVEIRA, J. F. A. *Instrumentação e segurança de barragens de terra e enrocamento*. Oficina de Textos, 2006.
- SU, H., LI, X., YANG, B., et al.. “Wavelet support vector machine-based prediction model of dam deformation”, *Mechanical Systems and Signal Processing*, v. 110, pp. 412–427, 2018. ISSN: 0888-3270. doi: <https://doi.org/10.1016/j.ymssp.2018.03.022>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0888327018301419>>.
- WEI, X., ZHANG, L., YANG, H.-Q., et al.. “Machine learning for pore-water pressure time-series prediction: Application of recurrent neural networks”, *Geoscience Frontiers*, v. 12, n. 1, pp. 453–467, 2021. ISSN: 1674-9871. doi: <https://doi.org/10.1016/j.gsf.2020.100508>.

1016/j.gsf.2020.04.011. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1674987120301134>>.

YILMAZ, I., KAYNAR, O. “Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils”, *Expert Systems with Applications*, v. 38, n. 5, pp. 5958–5966, 2011. ISSN: 0957-4174. doi: <https://doi.org/10.1016/j.eswa.2010.11.027>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417410012649>>.

ZHONG, Q., CHEN, S., SHAN, Y. “Prediction of the overtopping-induced breach process of the landslide dam”, *Engineering Geology*, v. 274, pp. 105709, 2020. ISSN: 0013-7952. doi: <https://doi.org/10.1016/j.enggeo.2020.105709>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0013795219321532>>.

ZOUNEMAT-KERMANI, M., RAJAEI, T., RAMEZANI-CHARMAHINEH, A., et al.. “Estimating the aeration coefficient and air demand in bottom outlet conduits of dams using GEP and decision tree methods”, *Flow Measurement and Instrumentation*, v. 54, pp. 9–19, 2017. ISSN: 0955-5986. doi: <https://doi.org/10.1016/j.flowmeasinst.2016.11.004>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0955598616302217>>.