









# SMB: Web-Based Dam Monitoring and Data Analysis System

Raimundo M. B. Neto , Victor F. Souza , Max J. L. P. Júnior , Iury G. O. Silva , Luiz S. S. M. Filho , Adam D. F. Santos , Reginaldo C. S. Filho , Hugo P. Kuribayashi , Carlos R. L. Francês , and João C. W. A. Costa 

**Abstract**—The monitoring and supervision of complex infrastructures, such as the dams and dikes of the Belo Monte Hydroelectric Plant, demand continuous data collection and analysis from various instruments (e.g., piezometers, surface markers, flow meters). In the context of structural health monitoring, recent advances propose the use of machine learning to recognize patterns and detect anomalies in monitoring data. This study presents a web-based application designed to support the early detection of structural anomalies through machine learning algorithms for anomaly detection, coupled with an interactive dashboard for data visualization. The system enables the establishment of baseline structural behavior and the identification of deviations that may indicate potential risks. Models were trained and tested with historical data, and multiple visualization tools were developed to facilitate the interpretation of results by engineers and decision-makers. The outcomes demonstrate that the proposed solution introduces innovative and effective technologies for the structural monitoring domain, contributing to the modernization of diagnostic processes and enhancing safety in critical energy infrastructure.

Link to graphical and video abstracts, and to code:  
<https://latam.ieeer9.org/index.php/transactions/article/view/10150>

**Index Terms**—Dam safety, machine learning, web application.

## I. INTRODUÇÃO

A NORTE ENERGIA S/A (NESA), concessionária responsável pelo Complexo Hidrelétrico de Belo Monte (CHBM), administra 36 estruturas registradas em seu sistema, entre barragens e diques. Neste estudo, foram analisadas especificamente duas dessas estruturas, apresentadas na Fig. 1: o Dique 6C e a Barragem Vertente do Santo Antônio (BVSA). Considerando a relevância dessas obras no contexto socioeconômico brasileiro, torna-se essencial o monitoramento

The associate editor coordinating the review of this manuscript and approving it for publication was Eduardo José da Luz (*Corresponding author: Raimundo Barros*).

This research was supported by Norte Energia S/A (NESA) through the P&D project PD-07427-0321/2021.

Raimundo Barros, and V. F. Souza are with the Center for Amazon Development in Engineering, Federal University of Pará, Tucuruí, Brazil (e-mails: raimundo.barros.neto, and victor.ferreira.souza:@tucuruí.ufpa.br).

M. J. L. P. Júnior, I. G. O. Silva, L. S. S. M. Filho, and R. C. S. Filho are with the Faculty of Computing, Federal University of Pará, Belém, Brazil (e-mails: max.junior@icen.ufpa.br, iury.silva@icen.ufpa.br, luiz.filho@icen.ufpa.br, and regicsf@ufpa.br).

A. D. F. Santos, and H. P. Kuribayashi are with the Faculty of Information Systems, Federal University of Southern and Southeastern Pará, Marabá, Brazil (e-mails: adamdreyton@unifesspa.edu.br, and hugo@unifesspa.edu.br).

C. R. L. Francês, and J. C. W. A. Costa are with the Faculty of Computer Engineering and Telecommunications, Federal University of Pará, Belém, Brazil (rfrances@ufpa.br, and jweyl@ufpa.br).

sistemático e a realização de inspeções visuais frequentes. Tais medidas visam detectar anomalias de forma precoce, permitindo ações preventivas que minimizam riscos ambientais e humanos [1] [2].



Fig. 1. Mapa com a localização da BVSA e do Dique 6C.

No setor de engenharia civil, técnicas de Aprendizado de Máquina (AM) e Monitoramento de Integridade Estrutural (Structural Health Monitoring – SHM) vêm se destacando como abordagens eficazes para a avaliação e preservação de estruturas críticas [3]. O SHM, em particular, representa uma evolução dos métodos tradicionais de monitoramento, permitindo a identificação e prevenção de falhas por meio de análises contínuas de sistemas físicos ou modelos paramétricos, empregando técnicas otimizadas com foco na detecção de desvios comportamentais [4].

O presente trabalho tem como objetivo explorar dados coletados por instrumentos de campo, a fim de gerar informações relevantes para a tomada de decisão relacionada à integridade estrutural das barragens (Dique 6C e BVSA). A principal contribuição é o desenvolvimento de uma aplicação web que integra modelos de AM para a detecção de anomalias em dados instrumentais, proporcionando uma ferramenta prática e eficiente para apoiar a operação e a segurança das estruturas monitoradas.

## II. TRABALHOS RELACIONADOS

Nos últimos anos, diversas abordagens baseadas em AM e modelagem estatística vêm sendo aplicadas para o monitoramento e avaliação estrutural de barragens, com foco na detecção de danos, previsão de comportamento e aumento da segurança operacional.

Os estudos de Morales *et al.* [5] e Overgaard *et al.* [6] apresentaram avanços relevantes para o SHM. O primeiro propôs um sistema em tempo real, de baixo custo computacional, para detectar e localizar danos com alta precisão, embora sem quantificar sua severidade. O segundo utilizou análise estocástica com o Método dos Elementos de Contorno, permitindo avaliações mais realistas da confiabilidade estrutural e integração com dados de monitoramento, mas demandando dados de qualidade e maior especialização para calibração.

O estudo de Mata *et al.* [7] analisou o comportamento dinâmico de uma barragem de concreto com base em variações no nível da água e temperatura. Foram aplicadas regressão linear múltipla e redes neurais multicamada. Já em [8], o foco foi a análise de movimentos relativos entre blocos, com definição de limiares para identificação de anomalias usando *Multi-Layer Perceptron* (MLP), contribuindo para maior precisão no monitoramento estrutural.

A avaliação modal operacional foi o foco do trabalho de Pereira *et al.* [9], que propôs uma metodologia sem necessidade de excitação artificial, utilizando modelos baseados em regressão linear e redes neurais. O estudo demonstrou que a incorporação de variáveis ambientais melhora a capacidade preditiva do comportamento estrutural.

A abordagem de Liu *et al.* [10] empregou o modelo *Kernel-Extreme Learning Machine* para prever a deformação de barragens em arco de concreto a partir de dados de temperatura do ar. O estudo demonstrou que a consideração dos efeitos térmicos é essencial para melhorar a precisão das previsões.

Kang *et al.* [11] utilizaram a técnica *Multivariate Adaptive Regression Splines* para modelar o comportamento de barragens com base em temperatura, destacando sua eficiência em reduzir erros de previsão e lidar com aproximações lineares complexas.

Embora esses trabalhos apresentem avanços significativos, a maioria concentra-se em prever deformações ou detectar danos estruturais com base em variáveis específicas, como fissuras, temperatura ou vibração. Diferenciando-se dessas abordagens, este trabalho propõe a detecção de anomalias diretamente em dados instrumentais de campo, utilizando limiares dinâmicos para classificar comportamentos normais e anômalos. Essa metodologia adaptativa visa uma resposta rápida e precisa a eventos inesperados, promovendo maior eficácia na manutenção preditiva e reforçando a segurança operacional das barragens, independentemente das condições ambientais.

## III. METODOLOGIA

O Sistema de Monitoramento de Barragens (SMB) tem por objetivo simplificar a utilização de modelos computacionais por profissionais técnicos especialistas na área de segurança de

barragens. A aplicação permite que os usuários insiram novos dados e conduzam análises através de painéis interativos.

O sistema proposto está fundamentado nos princípios do SHM. Nesse contexto, o SMB representa uma implementação prática de SHM baseada em dados instrumentais, onde os modelos de AM aprendem o comportamento estrutural normal além de monitorar os desvios da condição normal. Assim, o SHM é abordado de forma implícita, servindo como base conceitual que orienta a coleta, o processamento e a interpretação das medições instrumentais.

O SMB consiste em três partes principais: as detecções de anomalias manual e automática a partir de dados de instrumentação; a correlação e a clusterização de instrumentos; e o *dashboard* interativo com apresentação de informações processadas pelo sistema.

A interação do SMB com as equipes da NESA ocorre por meio de um conjunto de módulos de software em constante desenvolvimento, interligados por uma arquitetura cliente-servidor. Dentro desse contexto, todas as tecnologias de AM, softwares de gestão e bancos de dados são centralizados no servidor (*server-side*), componente essencial do SMB, permitindo que o acesso aos serviços seja feito pelo lado do cliente (*client-side*).

### A. Arquitetura da Aplicação web

A Fig. 2 ilustra a arquitetura utilizada e os principais componentes empregados no desenvolvimento do SMB. À direita da Fig. 2, pode-se observar o servidor, projetado para hospedar algoritmos de AM, fornecendo o serviço de detecção de anomalias. Toda essa infraestrutura é orquestrada pelo *backend* desenvolvido em Python (versão 3.9.10), utilizando o *framework* Django (versão 5.1.7). Tal linguagem de programação é amplamente empregada no desenvolvimento de aplicações web no *backend*, especialmente em contextos relacionados a AM, devido às suas notáveis características, tais como versatilidade multiplataforma, extensa variedade de bibliotecas, foco na produtividade e legibilidade [12].

O servidor é responsável por gerar modelos de AM destinados a aprimorar o monitoramento das estruturas. Sua função primordial é centralizar e consolidar todos os dados disponíveis para análise, incluindo o acesso e/ou espelhamento de dados brutos obtidos pelo software SYSDAM<sup>1</sup>, uma plataforma que apoia a gestão de segurança de barragens. Todos os dados da aplicação são armazenados no PostgreSQL, um banco relacional conhecido por sua robustez, desempenho e recursos avançados.

Para a criação do *frontend*, no qual os usuários interagem com as funcionalidades desenvolvidas, foi utilizada a linguagem de programação JavaScript com o *framework* React (versão 11.10.5), muito popular para o desenvolvimento de aplicações web interativas e de fácil manutenção.

É importante destacar que a interação entre *frontend* e *backend* é realizada através de requisições e respostas para/de uma API e que o *backend* e o banco de dados estão containerizados via Docker (versão 4.37.1). A containerização tem

<sup>1</sup>Para mais informações do SYSDAM acesse: <https://sysdam.com.br/sobre/empresa/>

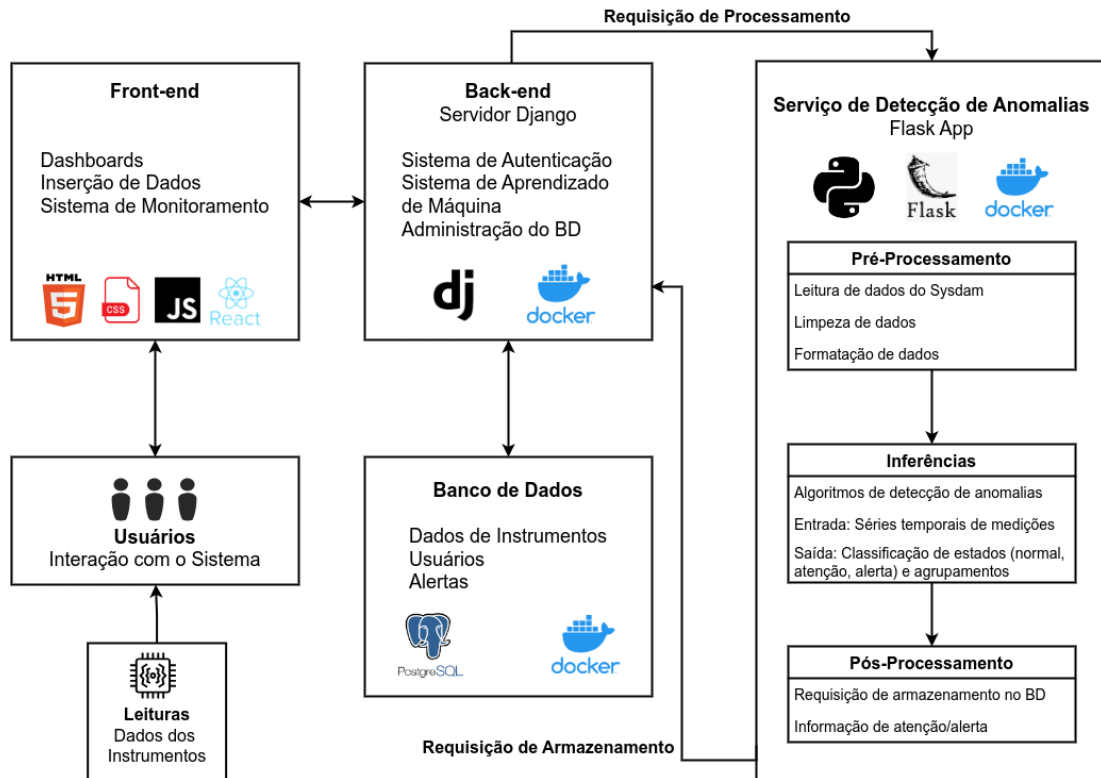


Fig. 2. Visão geral da arquitetura do SMB, onde são integrados as leituras, processamento e detecção de anomalias com LOF.

papel fundamental na arquitetura da aplicação web, pois traz benefícios como escalabilidade e integração contínua.

### B. Detecção de Anomalias em Dados de Instrumentos

As abordagens de AM trabalham para estabelecer uma relação funcional que modele como as variações nas condições operacionais e ambientais afetam a distribuição subjacente das características que são sensíveis a anomalias estruturais [13]. A detecção de anomalias é uma questão vital que tem sido objeto contínuo de estudo. Ao longo do tempo, uma variedade de métodos distintos foram desenvolvidos e aplicados para identificar essas anomalias em diferentes contextos. Esse tipo de detecção busca encontrar padrões em dados que não se alinham com o comportamento esperado, sendo uma tarefa fundamental em diversas áreas [14].

Após a avaliação de diferentes modelos de AM para detecção de anomalias, o algoritmo *Local Outlier Factor* (LOF) apresentou os melhores resultados para detecção de novidade (*novelty detection*). Além disso, o limiar gerado pelo LOF pode ser adaptativo, ajustando-se com base nas leituras mais próximas da leitura atual ao longo do tempo. Dessa forma, no SMB, o módulo de detecção de anomalias em dados de instrumentos adotou tal algoritmo.

O LOF é um método não supervisionado que estima o desvio de densidade local de uma observação em relação às suas vizinhas [15]. O modelo identifica como *outliers* as observações que exibem uma densidade menor em comparação com suas vizinhanças. As pontuações (*score*) para os dados, dependem do quão isolada a observação está em relação à vizinhança. Ao comparar a densidade local de uma observação

com as demais localidades, pode-se identificar observações que possuem uma densidade menor do que observações com maior densidade. Essas observações de menor densidade são consideradas anomalias e recebem *scores* negativos, enquanto observações provenientes de estados normais possuem *scores* positivos.

### C. Métrica de Avaliação dos Resultados

No SMB são considerados dois estados de anomalia: atenção e alerta. O estado de alerta apresenta uma anomalia com maior grau de severidade quando comparada com o estado de atenção. É importante frisar que para este estudo, é considerado uma anomalia qualquer resposta estrutural atípica que ultrapasse o limiar de confiança definido pelo modelo de AM. Uma anomalia não necessariamente significa um dano estrutural, pode também representar um erro de leitura, um erro no instrumento, algum efeito ambiental (temperatura, vento ou umidade) ou de carga.

O limiar estimado pelo modelo de AM é denominado de limiar de Inteligência Artificial (limiar de IA). Essa denominação é feita em função da existência de valores de controle (limiares) provenientes da etapa de concepção (limiar de Projeto) das estruturas. Destaca-se que os limiares de projeto são valores determinados com base em dados bibliográficos ou via modelos matemáticos e estatísticos. Dessa forma, a obtenção de limiares com base na série histórica de leituras da instrumentação (limiar de IA) é justificada pela necessidade de uma avaliação de tendência de comportamento, para que os limiares gerados pelo modelo de AM identifiquem anomalias de maneira precoce, antes mesmo dos limiares de projeto

serem atingidos. Portanto, os limiares de IA devem ser mais sensíveis na classificação das anomalias, se comparados com os limiares de projeto.

No CHBM<sup>2</sup>, existem aproximadamente 2.640 instrumentos, abrangendo 12 tipos distintos, destinados à avaliação periódica do desempenho de diversas estruturas. A leitura desses instrumentos é realizada de forma presencial, utilizando equipamentos destinados à finalidade de medição das grandezas. A frequência de leitura varia de acordo com o tipo de instrumento e a etapa em que a estrutura se encontra dentro do seu ciclo de vida. Adicionalmente, caso alguma anomalia seja constatada, o procedimento de leitura prevê a necessidade de redução do intervalo entre as leituras.

#### D. Detecções de Anomalias Manual e Automática

1) *Detecção de Anomalias Manual*: A detecção de anomalias manual considera que o usuário do software poderá definir quais dados serão utilizados para treinamento e teste do algoritmo de detecção de anomalias. Essa capacidade de definição é obtida através da seleção de datas de início e fim dos dados relacionados com determinado instrumento.

A possibilidade de o usuário definir os dados de treinamento do algoritmo de detecção de anomalias viabiliza a estimação de um modelo de AM mais sensível a detecção de dados anômalos, pois assume-se que a maioria dos usuários que irão utilizar este tipo de detecção tem o perfil técnico, o que implica na seleção de dados com mais qualidade para o aprendizado do algoritmo.

2) *Detecção de Anomalias Automática*: Na detecção de anomalias automática, considera-se que o usuário do software não poderá definir quais dados serão utilizados para treinamento e teste do algoritmo. Portanto, neste caso, os dados de treinamento e teste são selecionados automaticamente.

Para seleção automática de dados de treinamento a partir de um instrumento selecionado pelo usuário, se faz necessário excluir *outliers* dos dados da série temporal do instrumento em questão. Dessa forma, apenas dados da condição estrutural normal, ou seja, sem atenções e/ou alertas, serão empregados na etapa de treinamento do modelo de AM para detecção de anomalias. Por consequência, os dados excluídos do treinamento são automaticamente disponibilizados para a execução da etapa de teste.

Além disso, na detecção de anomalias automática, se alguma anomalia for identificada no instrumento selecionado pelo usuário, todos os procedimentos de detecção de anomalias serão também executados para os instrumentos adjacentes ao instrumento selecionado, com auxílio da aplicação de técnicas de agrupamento/clusterização e correlação estatística.

3) *Correlação e Clusterização de Instrumentos*: Na correlação de instrumentos é conduzida uma análise completa da situação anômala, levando em consideração instrumentos que pertencem ao mesmo *cluster* daquele em análise. Essa abordagem, presente no SMB, resulta do treinamento de um algoritmo de AM que realiza a clusterização, além da

aplicação de técnicas de correlação linear nas séries históricas dos instrumentos.

A clusterização entre instrumentos envolve agrupá-los com base em sua proximidade geográfica, utilizando o algoritmo K-means [16]. Esse processo reúne no mesmo *cluster* os instrumentos que estão fisicamente próximos uns dos outros, considerando sua longitude, latitude e altura em relação ao solo da estrutura. Essa clusterização fornece ao inspetor de barragens informações sobre quais instrumentos estão agrupados. Isso é valioso porque, em caso de detecção de uma anomalia em um instrumento específico, o inspetor pode realizar uma análise abrangente do problema, investigando quais outros instrumentos também podem indicar anomalias. Isso oferece uma visão do alcance da anormalidade na estrutura. Essa análise macro pode sugerir planos de ação mais completos e auxiliar os especialistas na tomada de decisões, inclusive antecipando o surgimento de anomalias.

#### E. Dashboard

No módulo de *dashboard*, os usuários podem interagir com a aplicação podendo realizar as seguintes ações principais: (1) Seleção de estrutura (barragem ou dique) e instrumentos a partir dos quais os dados serão processados; (2) Filtragem de dados de determinado instrumento ao longo do tempo com objetivo de visualização; (3) Seleção do arquivo de entrada de dados para processamento, armazenamento no banco de dados e posterior visualização; (4) Seleção do eixo de deslocamento do instrumento (horizontal e vertical); (5) Seleção de limiares de IA e de projeto.

Além disso, ainda no *dashboard*, considerando que os dados provenientes dos instrumentos tenham sido processados, os usuários podem realizar as seguintes visualizações de informações: (1) Séries temporais de dados de instrumentos, considerando seus diferentes eixos de deslocamento e os limiares de IA e de projeto; (2) Percentuais e valores absolutos de observações de anomalias nos dados de determinado instrumento; (3) Percentuais e estatística descritiva de cada estado (normal, atenção e alerta) das medições dos instrumentos; (4) Localização dos instrumentos na estrutura.

## IV. RESULTADOS

### A. Recursos do SMB

Na Fig. 3, é exibida a tela inicial do SMB, onde é possível verificar um menu lateral que apresenta todas as funcionalidades da aplicação de forma clara e objetiva. Esse menu está dividido em quatro partes principais:

- 1) *Home*: página inicial para a qual o usuário é direcionado ao acessar o sistema, onde também são descritas informações do sistema desenvolvido;
- 2) *Dashboard*: visualização interativa de informações gráficas e quantitativas pós-processadas, a partir de dados de instrumentos, para análise por parte dos especialistas;
- 3) *Inteligência Artificial*: possibilita a utilização dos modelos de AM para detecção de anomalias, com a seleção de estruturas, instrumentos e um período para treinamento e teste dos modelos;

<sup>2</sup>Para mais informações do CHBM acesse: <https://www.norteenergiass.com.br/>



Fig. 3. Menu principal da aplicação web, onde é possível visualizar os menus da aplicação, além dos atalhos rápidos na tela principal.

- 4) Painel de controle: menu gerencial do sistema, com funcionalidades que incluem cadastro e edição de usuários, estruturas, instrumentos, modelos de AM e definição de limiares de detecção de anomalias.

### B. Resultados da Detecção de Anomalias Manual e Automática

1) *Detecção de Anomalias Manual*: A Fig. 4 apresenta os passos iniciais para o treinamento do modelo de detecção de anomalias manual. O usuário deve realizar a seleção de uma estrutura, do instrumento e do período que será utilizado para a obtenção dos dados do treinamento, conforme exemplifica a Fig. 4a. Em seguida, na Fig. 4b, é realizada a confirmação das informações selecionadas e habilita-se a possibilidade de treinar o modelo.

Na etapa de teste, da mesma forma como na etapa de treino, também é realizada a seleção da estrutura, do instrumento e do período desejado para a realização do teste. Após a seleção, procede-se à confirmação dos dados escolhidos e habilita-se a possibilidade de testar um modelo de detecção de anomalias já treinado.

A Fig. 5, apresenta o limiar de IA estimado, resultante da detecção de anomalias manual, onde é possível verificar que o limiar de IA tornou-se mais sensível (menor) do que o limiar de projeto. Destaca-se que esse resultado está alinhado com a necessidade de que os limiares históricos proporcionais pela aplicação desenvolvida sejam uma solução com capacidade de detectar anomalias incipientes e logo que possível, notificar os usuários da ferramenta.

Ao assumir que o limiar de projeto classifica corretamente todos os dados provenientes dos estados normal e anormal, a detecção de anomalias manual obteve precisão, revocação e f1-score para as classes normal e anormal tal que, respectivamente: 1, 0.8 e 0.89; 0.78, 1 e 0.88. Logo, considerando que na etapa de teste 233 observações normais e 166 observações são anormais via limiar de projeto, a detecção de anomalias

manual desempenha exatamente o papel de identificar prontamente anomalias, mesmo que ocorram alguns falso-positivos, o que é refletido na revocação perfeita na classe anormal.

2) *Detecção de Anomalias Automática*: Na detecção de anomalias automática, o SMB define automaticamente quais dados serão utilizados para treino e teste do modelo (Fig. 6). Contudo, o usuário deve selecionar a estrutura e o instrumento que será analisado, conforme é exibido na Fig. 6a. Além disso, o usuário deve definir a quantidade de vizinhos que serão analisados na correlação (Fig. 6b). Assim, o sistema automaticamente correlaciona, por meio de clusterização, os instrumentos que fazem parte da vizinhança do instrumento principal que está sendo analisado.

Os resultados da detecção de anomalias automática são apresentados na Fig. 7. Da mesma forma como na detecção de anomalias manual, os limiares de IA continuaram sendo mais sensíveis para a detecção de anomalias automática, que se enquadram no nível de atenção, enfatizando uma performance melhorada se comparado com os limiares de projeto, a fim de identificar problemas de forma precoce nas estruturas.

Juntamente com os resultados da detecção de anomalias automática, também é possível verificar os resultados da clusterização aplicada nos vizinhos que compõem o *cluster* do instrumento primário (PZ-BM-BV-52). Nas Figs. 8 e 9 é possível verificar dois instrumentos que foram correlacionados, são os instrumentos PZ-BM-BV-54 e o instrumento PZ-BM-BV-53 respectivamente.

Similar à análise do instrumento principal (PZ-BM-BV-52), os limiares de IA também seguiram mais sensíveis que os limiares de projeto na análise dos instrumentos vizinhos, resultantes da correlação. É importante frisar que a correlação de instrumentos contribui para que os especialistas em segurança de barragens possam rastrear se uma anomalia se propagou para instrumentos vizinhos ao que foi selecionado primeiramente.

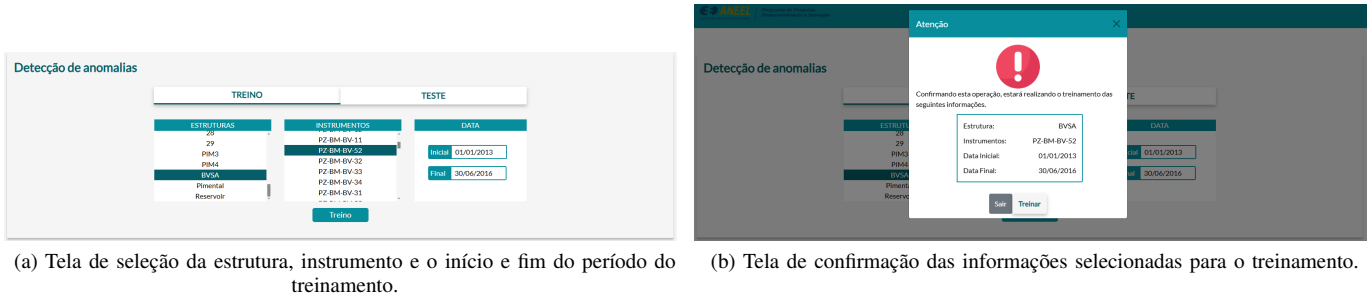


Fig. 4. Telas de seleção dos parâmetros e confirmação do treinamento de detecção de anomalias manual.

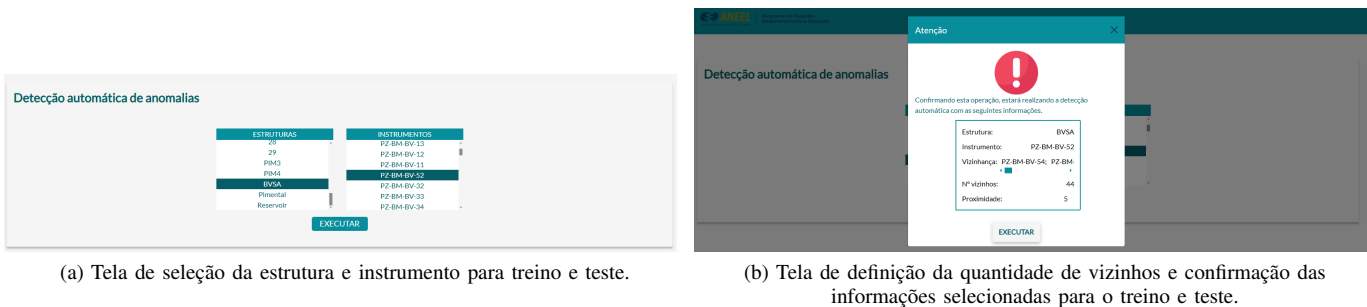
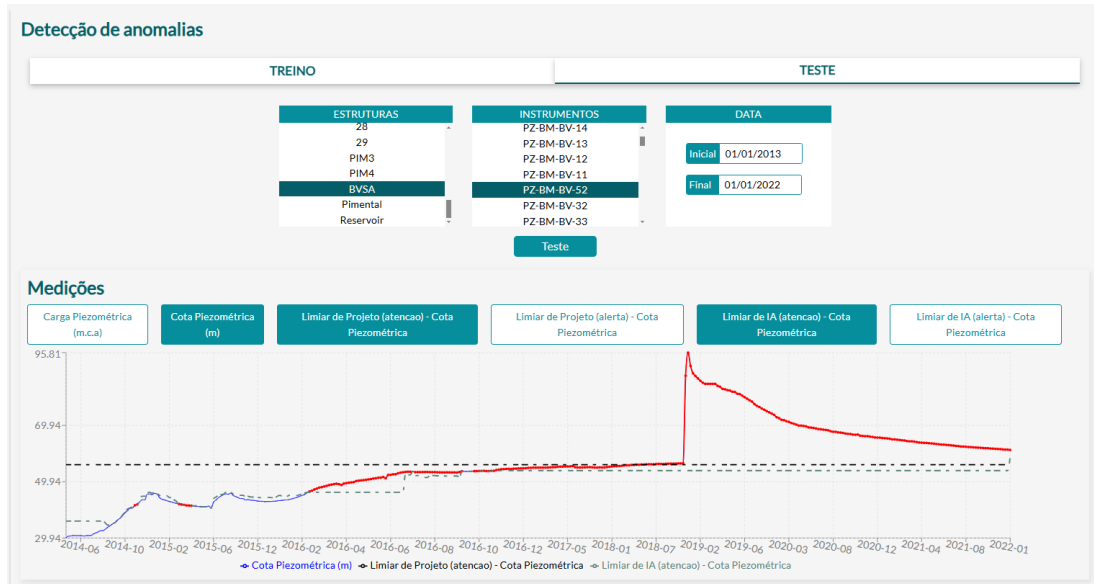


Fig. 6. Telas de seleção dos parâmetros e confirmação do treino e teste de detecção de anomalias automática.

V. CONCLUSÕES

Este trabalho apresentou o SMB, uma aplicação web com o objetivo de facilitar a identificação de possíveis comportamentos anômalos a partir de dados da instrumentação de estruturas presentes no Complexo Hidrelétrico de Belo Monte. A aplicação é composta por três partes principais: detecção de anomalias manual e automática, correlação e clusterização de instrumentos e o *dashboard* interativo. Ademais, a arquitetura da aplicação obedece práticas modernas de containerização de seus componentes (*frontend*, *backend* e banco de dados), oferecendo funcionalidades importantes como serviços.

Por meio do *dashboard* interativo é possível visualizar informações que podem auxiliar na tomada de decisão dos usuários em termos de segurança das barragens e diques. Os destaques das visualizações possíveis no *dashboard* podem ser sintetizados pela análise temporal das medições dos instrumentos com ou sem limiares (IA e projeto), análise percentual de possíveis anomalias detectadas e estatística das medições dos instrumentos, assumindo os estados de normalidade e anormalidade (atenção e alerta).

O módulo de detecção de anomalias (manual e automática) apresentou funcionalidades para treinamento e teste de mod-

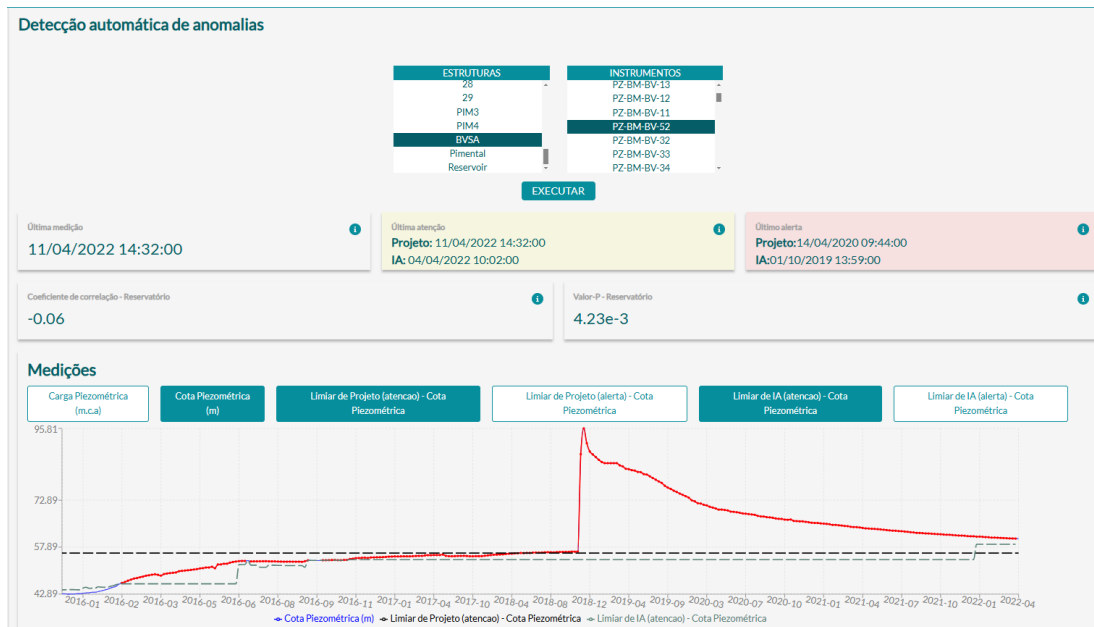


Fig. 7. Resultados visuais da detecção de anomalias automática, com os limiares de IA e Projeto para detecção automática de dados na condição de Atenção.

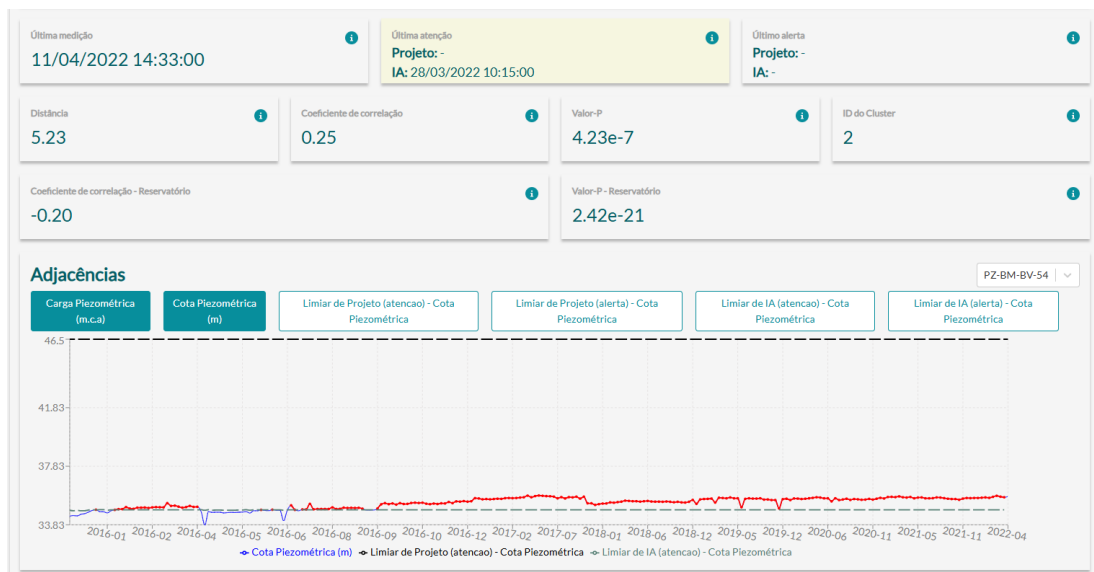


Fig. 8. Resultados visuais com o resultado de correlação do instrumento PZ-BM-BV-54 e com os limiares de IA e Projeto para detecção de dados na condição de Atenção.

elos de AM para detecção de anomalias em dados de instrumentos, considerando os estados anormais de atenção e alerta. Tais modelos, depois de treinados, armazenam parâmetros que simbolizam o comportamento normal que foi mensurado por determinado instrumento, além de também guardar limiares históricos que quando superados indicam condições anômalas. Os testes dos modelos treinados proporcionam a classificação de novas medições como normal, atenção ou alerta, de acordo com os limiares históricos estimados no treinamento.

É crucial destacar que com os limiares históricos, os quais são gerados pelo módulo de detecção de anomalias, o objeto foi possibilitar mais sensibilidade na tarefa de detecção de anomalias (índices menores), no sentido de que o AM possa

indicar uma condição anômala incipiente, antes da indicação de tal condição via limiares de projeto.

Apesar dos resultados promissores, o algoritmo LOF, por ser baseado em densidade, é sensível à escolha do número de vizinhos e pode ter seu desempenho alterado em distribuições muito heterogêneas. Além disso, a coleta de dados dos instrumentos é realizada manualmente por leitores, desta forma a frequência e a qualidade das leituras, se efetuados erroneamente, impactam diretamente o desempenho do modelo.

#### AGRADECIMENTOS

Os autores agradecem o suporte financeiro recebido pela Norte Energia S/A (PD-07427-0321/2021) durante a execução

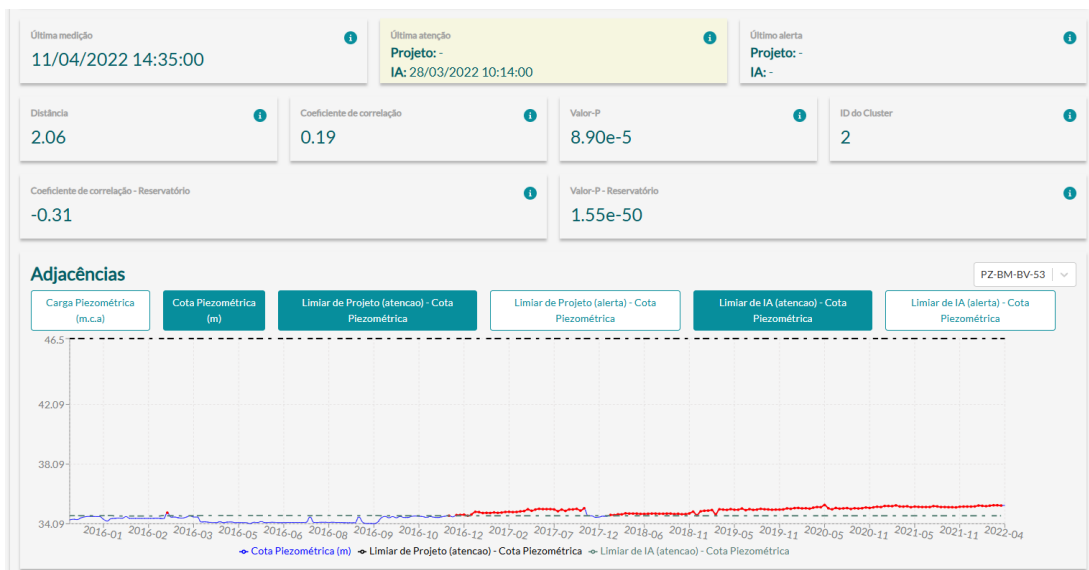


Fig. 9. Resultados visuais com o resultado de correlação do instrumento PZ-BM-BV-53 e com os limiares de IA e Projeto para detecção de dados na condição de Atenção.

do Projeto de P&D “Estratégias baseadas em SHM, *Machine e Deep Learning* para extração de padrões em estruturas críticas da UHE Belo Monte”.

## REFERÊNCIAS


- [1] R. Gomasa, V. Talakokula, S. Kalyana Rama Jyosyula, and T. Bansal, “A review on health monitoring of concrete structures using embedded piezoelectric sensor,” *Construction and Building Materials*, vol. 405, p. 133179, 2023. [Online]. Available: <https://doi.org/10.1016/j.conbuildmat.2023.133179>.
- [2] J. Hu and S. Wu, “Statistical modeling for deformation analysis of concrete arch dams with influential horizontal cracks,” *Structural Health Monitoring*, vol. 18, no. 2, pp. 546–562, 2019. [Online]. Available: <https://doi.org/10.1177/1475921718760309>.
- [3] W. B. C. M. Flah, I. Nunez and M. L. Nehdi, “Machine learning algorithms in civil structural health monitoring: A systematic review,” *Archives of Computational Methods in Engineering*, vol. 28, pp. 2621–2643, June 2021. [Online]. Available: <https://doi.org/10.1007/s11831-020-09471-9>.
- [4] L. C. d. S. M. Ozelim, L. P. d. F. Borges, A. L. B. Cavalcante, E. A. C. Albuquerque, M. d. S. Diniz, M. S. Góis, K. R. C. B. d. Costa, P. F. d. Sousa, A. P. d. N. Dantas, R. M. Jorge, *et al.*, “Structural health monitoring of dams based on acoustic monitoring, deep neural networks, fuzzy logic and a cusum control algorithm,” *Sensors*, vol. 22, no. 7, p. 2482, 2022. [Online]. Available: <https://doi.org/10.3390/s22072482>.
- [5] J. Morales Valdez, L. Alvarez-Icaza, and J. A. Escobar, “Online identification system for damage location in building structures,” *IEEE Latin America Transactions*, vol. 17, no. 08, pp. 1283–1290, 2019. [Online]. Available: <https://doi.org/10.1109/TLA.2019.8932337>.
- [6] B. Quiero Hernández and G. Rojas, “Automatic code generation of data visualization for structural health monitoring,” *IEEE Latin America Transactions*, vol. 20, no. 7, pp. 1041–1050, 2022. [Online]. Available: <https://doi.org/10.1109/TLA.2021.9827466>.
- [7] J. Mata, J. P. Gomes, S. Pereira, F. Magalhães, and Álvaro Cunha, “Analysis and interpretation of observed dynamic behaviour of a large concrete dam aided by soft computing and machine learning techniques,” *Engineering Structures*, vol. 296, p. 116940, 2023. [Online]. Available: <https://doi.org/10.1016/j.engstruct.2023.116940>.
- [8] J. Mata, F. N. Miranda, A. Antunes, X. Romão, and J. P. Santos, “Characterization of relative movements between blocks observed in a concrete dam and definition of thresholds for novelty identification based on machine learning models,” *Water*, vol. 15, no. 2, pp. 297–297, 2023. [Online]. Available: <https://doi.org/10.3390/w15020297>.
- [9] S. Pereira, J. Mata, F. Magalhães, J. Gomes, and Álvaro Cunha, “Predicting the dynamic behaviour of a concrete dam using statistical and machine learning models,” *E-Journal of nondestructive testing*, vol. 29, no. 7, 2024. [Online]. Available: <https://doi.org/10.58286/29856>.
- [10] X. Liu, F. Kang, C. Ma, and H. Li, “Concrete arch dam behavior prediction using kernel-extreme learning machines considering thermal effect,” *Journal of Civil Structural Health Monitoring*, vol. 11, no. 2, pp. 283–299, 2021. [Online]. Available: <https://doi.org/10.1007/S13349-020-00452-X>.
- [11] F. Kang, X. Liu, J. Li, and J. Li, “Concrete dam behavior prediction using multivariate adaptive regression splines with measured air temperature,” *Arabian Journal for Science and Engineering*, vol. 44, no. 10, pp. 8661–8673, 2019. [Online]. Available: <https://doi.org/10.1007/S13369-019-04095-Z>.
- [12] J. R. d. Sousa, J. F. Antunes, I. A. d. Oliveira, J. C. R. Leite, T. M. d. S. M. Souza, and T. G. S. d. Santos, “Python and data prediction using multi-layered neural networks,” *Brazilian Journal of Development*, vol. 6, p. 54181–54185, Aug. 2020. [Online]. Available: <https://doi.org/10.34117/bjdv6n7-897>.
- [13] K. Worden and G. Manson, “The application of machine learning to structural health monitoring,” *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 365, no. 1851, pp. 515–537, 2007. [Online]. Available: <https://doi.org/10.1098/rsta.2006.1938>.
- [14] A. B. Nassif, M. A. Talib, Q. Nasir, and F. M. Dakalbab, “Machine learning for anomaly detection: A systematic review,” *IEEE Access*, vol. 9, pp. 78658–78700, 2021. [Online]. Available: <https://doi.org/10.1109/ACCESS.2021.3083060>.
- [15] M. M. Breunig, H.-P. Kriegel, R. T. Ng, and J. Sander, “Lof: Identifying density-based local outliers,” *SIGMOD Rec.*, vol. 29, p. 93–104, may 2000. [Online]. Available: <https://doi.org/10.1145/335191.335388>.
- [16] J. A. Hartigan and M. A. Wong, “Algorithm as 136: A k-means clustering algorithm,” *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, vol. 28, no. 1, pp. 100–108, 1979. [Online]. Available: <https://doi.org/10.2307/2346830>.



**Raimundo M. B. Neto.** received the B.Sc. degree in Information Systems from the Federal University of Southern and Southeastern Pará (UNIFESSPA), Marabá, Brazil, in 2021. He is currently a master’s student at the Federal University of Pará (UFPA), where he works on Applied Computing projects in Structural Integrity Monitoring using Machine Learning techniques.



**Victor F. Souza** received the B.Sc. degree in Information Systems from the Federal University of Southern and Southeastern Pará (UNIFESSPA), Marabá, Brazil, in 2021. He is currently a master's student at the Federal University of Pará (UFPA), focusing on Machine Learning projects with an emphasis on Large Language Models and Data Science.



**Max J. L. P. Júnior** received the B.Sc. degree in Computer Science at the Federal University of Pará (UFPA), Belém, Brazil, in 2022. He has experience with web development, data mining, data science, and has worked on projects involving MBA (Market Basket Analysis). The research areas that interest him most involve the improvement of optimization and machine learning algorithms, as well as the application of data science and data mining to extract meaningful insights from data sets.



**Iury G. O. Silva** received the B.Sc. degree in Computer Science from the Federal University of Pará (UFPA), Belém, Brazil, in 2023. Currently working with development and maintenance of banking systems. I participated in research projects focusing on non-deterministic population algorithms and Computer Vision (Structural Health Monitoring).



**Luiz S. S. M. Filho** received the B.Sc. degree in Laws from the University Center of Pará (CESUPA), Belém, Brazil, in 2019. Currently studying Computer Science at the Federal University of Pará (UFPA), Belém, Brazil. Volunteer at the Artificial Intelligence Laboratory (LAAI) performing research in the area of performance analysis. His main academic interests are: data science and analysis, data engineering, data mining techniques, and jurimetrics.



**Adam D. F. Santos** received the M.Sc. degree in electrical engineering (telecommunications) from the Federal University of Pará (UFPA), Belém, Brazil, in 2014, where he also received the Ph.D. degree in electrical engineering (applied computing) in 2017. He is currently an Adjunct Professor at the Federal University of Southern and Southeastern Pará (UNIFESSPA), a Researcher at the Center of Excellence in Artificial Intelligence at the Federal University of Goiás (UFG), and a permanent professor at the PPGCF and PPCA, developing research

related to artificial intelligence methods applied to complex systems problems.



**Reginaldo C. S. Filho** received the M.Sc. degree in Computer Science from the Federal University of Pará (UFPA), Belém, Brazil, in 2016, where he also received his Ph.D. in Computer Science in 2019. He is currently a professor and vice-rector of the Faculty of Computing (FACOMP) and a member of the Graduate Program in Computer Science (PPGCC). His main scientific interests are: improving metaheuristics for multimodal optimization problems, using machine learning algorithms for pattern detection, and extracting non-trivial information from

databases through data science and data mining technologies.



**Hugo P. Kuribayashi** received the M.Sc. degree in Computer Science from the Federal University of Pará (UFPA), Belém, Brazil, in 2011, where he also obtained his Ph.D. in Electrical Engineering with an Emphasis in Applied Computing, in 2021. He is currently a professor at the Federal University of Southern and Southeastern Pará (UNIFESSPA) and the Postgraduate Program in Forensic Sciences (PPGCF). He has experience in Computing, with an emphasis on Data Analysis, Machine Learning Methods, and Cybersecurity.



**Carlos R. L. Francês** received the M.Sc. degree in Computer Science from the University of São Paulo (USP), São Paulo, Brazil, in 1998, where he also obtained his Ph.D. in Computer Science and Computational Mathematics, in 2001. Currently, he is a professor at the Faculty of Computer Engineering and Telecommunications of the Federal University of Pará (UFPA). He has experience in the areas of Telecommunications Systems and Applied Computing, Telecommunications Systems, Applied Computing: Artificial Intelligence Techniques and

Computer Vision.



**João C. W. A. Costa** received the M.Sc. degree in electrical engineering from the Pontifical Catholic University of Rio de Janeiro, Brazil, in 1989, and the Ph.D. degree in electrical engineering from the State University of Campinas, Campinas, Brazil, in 1994. Currently professor and vice-dean of the Faculty of Computing (FACOMP), member of the Graduate Program in Electrical Engineering (PPGEE) of the Federal University of Pará (UFPA). Main scientific interests are: improving metaheuristics for multimodal optimization problems, using machine learning algorithms to detect patterns and extracting nontrivial information from databases through data science and data mining technologies.