



PONTES E TALUDES FERROVIÁRIOS, MONITORAMENTO INTEGRADO PARA DETECÇÃO PREDITIVA DE DANOS BASEADO EM INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO AVANÇADO

Glauco Fernandes De Oliveira Nunes ¹;

¹Universidade Federal De Minas Gerais — BRASIL

RESUMO

Este estudo propõe um sistema integrado de monitoramento inteligente aplicado a infraestruturas ferroviárias, com foco na detecção preditiva de danos em pontes e taludes. A metodologia combina técnicas de monitoramento estrutural, instrumentação geotécnica, sensoriamento remoto e inteligência artificial. Foram analisados modelos baseados em ARX, PCA e fusão de dados, aliados a tecnologias como InSAR, LiDAR e sensores IoT. Os resultados indicam que a integração multimodal permite maior sensibilidade na detecção precoce de anomalias, reduzindo riscos operacionais e custos de manutenção. Conclui-se que a abordagem proposta representa avanço significativo na transição da manutenção corretiva para preditiva em sistemas ferroviários.

Palavras-chave: Monitoramento ferroviário; Pontes; Taludes; Inteligência artificial;

1. INTRODUÇÃO

A infraestrutura ferroviária constitui um dos pilares fundamentais para o desenvolvimento econômico, logístico e territorial, desempenhando papel estratégico no transporte de cargas e passageiros em escala regional e nacional. Nesse contexto, elementos estruturais como pontes ferroviárias e estruturas geotécnicas associadas, como taludes de corte e aterro, assumem função crítica na garantia da continuidade operacional e da segurança do sistema (PALIN *et al.*, 2021; THADURI; GARMABAKI; KUMAR, 2021).

Entretanto, ao longo do ciclo de vida dessas estruturas, diversos mecanismos de degradação atuam de forma simultânea e progressiva, incluindo fadiga estrutural, corrosão, variações térmicas e instabilidades geotécnicas, os quais podem comprometer significativamente o desempenho e a integridade dessas infraestruturas (MATSUOKA; TOKUNAGA; KAITO, 2021; FREDLUND; MORGENSTERN; WIDGER, 1978).

Historicamente, a gestão da infraestrutura ferroviária tem sido baseada em estratégias de manutenção corretiva ou preventiva, frequentemente dependentes de inspeções periódicas e avaliações visuais. Contudo, tais abordagens apresentam limitações importantes, sobretudo no que se refere à detecção precoce de danos e à capacidade de antecipação de falhas (DATTEO *et al.*, 2018; FIGUEIREDO *et al.*, 2011).

Nesse cenário, os sistemas de Monitoramento de Integridade Estrutural (Structural Health Monitoring – SHM) emergem como ferramentas promissoras, permitindo a aquisição contínua de dados e a avaliação em tempo real do comportamento estrutural (FINOTTI; CURY; BARBOSA, 2019; MEIXEDO *et al.*, 2021).



Paralelamente, os avanços recentes em tecnologias de sensoriamento remoto e redes de sensores têm ampliado significativamente a capacidade de monitoramento em larga escala, especialmente em regiões suscetíveis a instabilidades geotécnicas (GUILHOT; DEL HOYO; BARTOLI, 2021; Piroton *et al.*, 2020).

Apesar desses avanços, observa-se na literatura uma lacuna relevante: a maioria dos estudos trata de forma isolada o monitoramento estrutural de pontes ou o monitoramento geotécnico de taludes, carecendo de abordagens integradas que considerem a interação entre os diferentes subsistemas da infraestrutura ferroviária (MALEKJAFARIAN; CORBALLY; GONG, 2022; QUANG *et al.*, 2018).

2. DESENVOLVIMENTO

O presente estudo foi desenvolvido em ambiente computacional e conceitual integrado, com base em uma abordagem multimodal para o monitoramento inteligente de infraestruturas ferroviárias, contemplando pontes e taludes. Sua concepção fundamenta-se em recursos laboratoriais, computacionais e bibliográficos compatíveis com aqueles disponíveis em instituições de excelência, como a Universidade Federal de Minas Gerais, em especial no âmbito do Departamento de Engenharia de Estruturas da UFMG, linha de pesquisa 4 – Planejamento, projetos e operações de sistemas construtivos e de TRANSPORTES que dispõe de infraestrutura adequada para pesquisas nas áreas de engenharia estrutural, geotecnia, sensoriamento remoto e inteligência artificial.

A metodologia adotada combina aquisição de dados multimodal, processamento computacional e modelagem preditiva, considerando dados representativos de condições reais de operação ferroviária, conforme abordagens recentes em monitoramento estrutural e interação veículo-estrutura (MALEKJAFARIAN; CORBALLY; GONG, 2022). O objetivo consiste em permitir a detecção precoce de danos estruturais e geotécnicos, alinhando-se aos princípios do monitoramento de integridade estrutural, amplamente discutidos na literatura (DATTEO *et al.*, 2018).

A estrutura metodológica foi organizada em quatro etapas principais e interdependentes: (i) aquisição e integração de dados provenientes de sensores estruturais, instrumentação geotécnica e sensoriamento remoto; (ii) transmissão, armazenamento e gerenciamento dos dados em ambiente digital; (iii) processamento, filtragem e análise por meio de técnicas estatísticas e algoritmos de inteligência artificial, incluindo métodos de redução de dimensionalidade como a Análise de Componentes Principais (PCA) (MEIXEDO *et al.*, 2021); e (iv) detecção e classificação de anomalias, com base em modelos preditivos aplicados a séries temporais, tais como modelos autoregressivos com entradas exógenas (ARX), amplamente utilizados na identificação de sistemas estruturais (MEIXEDO *et al.*, 2022).

2.1 Materiais utilizados

2.1.1 Sensores e equipamentos

Foram considerados diferentes tipos de sensores e equipamentos, de forma a representar um sistema multimodal de monitoramento:



Tabela 1 Tecnologias de monitoramento aplicadas a infraestruturas ferroviárias

TECNOLOGIA	ONDE É UTILIZADA	QUANDO É UTILIZADA	FINALIDADE PRINCIPAL
Acelerômetros (vibração)	Pontes ferroviárias / veículos ferroviários	Durante operação (passagem de trens)	Identificação de alterações dinâmicas e detecção indireta de danos estruturais
Extensômetros (strain gauges)	Elementos estruturais de pontes	Monitoramento contínuo ou campanhas específicas	Medição de deformações e tensões
Sensores de vibração embarcados	Veículos ferroviários	Em operação (monitoramento drive-by)	Avaliação indireta da integridade estrutural
Piezômetros	Taludes de corte e aterro	Monitoramento contínuo (especialmente em períodos chuvosos)	Medição da pressão de poros e estabilidade geotécnica
Inclinômetros	Taludes ferroviários	Monitoramento periódico ou contínuo	Detecção de deslocamentos internos do solo
Sensores de umidade do solo	Taludes e subleito ferroviário	Períodos críticos (chuvas intensas)	Avaliação da saturação e risco de instabilidade
InSAR (satélite SAR)	Regiões extensas ao longo da ferrovia	Monitoramento periódico (dias a semanas)	Detecção de deformações milimétricas em larga escala
LiDAR (aéreo ou drone)	Taludes, cortes e entorno da ferrovia	Levantamentos periódicos	Modelagem topográfica e identificação de mudanças geométricas
Câmeras RGB (drones)	Inspeção visual de pontes e taludes	Inspeções programadas	Identificação visual de fissuras, erosões e danos superficiais
Sistemas IoT (redes de sensores)	Ao longo da ferrovia (pontes e taludes)	Monitoramento contínuo	Coleta e transmissão de dados em tempo real
Sistemas de aquisição de dados (DAQ)	Estações de monitoramento	Contínuo ou sob demanda	Armazenamento e gerenciamento de dados
Modelos ARX	Processamento computacional	Após coleta de dados	Modelagem do comportamento estrutural
PCA (Análise de Componentes Principais)	Processamento de dados	Pré-processamento	Redução de ruído e identificação de padrões



Detecção de anomalias (Mahalanobis)	Análise estatística	Pós-processamento	Identificação de eventos fora do padrão
-------------------------------------	---------------------	-------------------	---

2.1.2 Softwares E Ferramentas Computacionais

Para o processamento e análise dos dados, foram utilizados:

- **PYTHON** (bibliotecas NumPy, SciPy e Scikit-learn), para modelagem e análise estatística;
- **MATLAB**, para validação de modelos e processamento de sinais;
- **QGIS**, para análise espacial e geração de mapas de suscetibilidade;
- **PLATAFORMAS EM NUVEM (AWS/AZURE)**, para armazenamento e gerenciamento de dados.

2.2 Métodos E Procedimentos

2.2.1 Aquisição E Integração De Dados

Os dados foram obtidos a partir de múltiplas fontes, incluindo sensores embarcados em veículos ferroviários, instrumentação geotécnica instalada em campo e imagens de sensoriamento remoto. A integração desses dados foi realizada por meio de técnicas de fusão de dados, permitindo a construção de um banco de dados unificado.

O período de coleta de dados considerado neste estudo foi simulado com base em séries temporais representativas de monitoramento contínuo, com frequência de aquisição variando entre 1 Hz (sensores estruturais) e dados periódicos de satélite (InSAR).




Figura 1. Fluxograma para os dados foram obtidos a partir de múltiplas fontes, incluindo sensores embarcados em veículos ferroviários.



A abordagem metodológica adotada está alinhada com estudos recentes que exploram a integração de sensores distribuídos e técnicas de inteligência artificial para monitoramento estrutural e geotécnico, destacando-se a utilização de modelos baseados em aprendizado de máquina e análise de séries temporais (WANG *et al.*, 2022; KOMARIZADEHASL *et al.*, 2022).

Adicionalmente, a utilização de redes de sensores IoT e instrumentação geotécnica distribuída segue tendências observadas em sistemas modernos de monitoramento de encostas e infraestrutura crítica (GAMPERL; SINGER; THURO, 2021; MARINO *et al.*, 2023).

2.2.2 Processamento De Sinais

Os sinais coletados foram submetidos a técnicas de filtragem e normalização para redução de ruído e eliminação de interferências ambientais. Foi aplicada a Análise de Componentes Principais (PCA) para redução de dimensionalidade e identificação de padrões relevantes nos dados.

2.2.3 Modelagem Matemática

A modelagem do comportamento estrutural foi realizada por meio de modelos autoregressivos com entradas exógenas (ARX), descritos pela Equação (1):

$$y(t) = \sum_{i=1}^n a_i y(t-i) + \sum_{j=1}^m b_j u(t-j) + e(t) \quad (1)$$

onde:

- $y(t)$ representa a saída do sistema (resposta estrutural);
- $u(t)$ representa a entrada (excitação);
- a_i e b_j são coeficientes do modelo;
- $e(t)$ é o erro residual.

2.2.4 Detecção de anomalias

A identificação de danos foi realizada por meio de análise estatística multivariada, utilizando a distância de Mahalanobis como métrica para detecção de outliers. Valores acima de um limiar predefinido foram classificados como potenciais anomalias estruturais ou geotécnicas.

$$D_M(x) = \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)} \quad (2)$$



- x – vetor de observações;
- μ – vetor de médias multivariadas;
- Σ – matriz de covariância;
- Valores de $D_M^2 > \chi_{(p, 0.99)}^2$ foram classificados como anomalias.

2.2.5 Análise espacial e monitoramento geotécnico

Os dados de sensoriamento remoto foram utilizados para geração de mapas de suscetibilidade a deslizamentos, integrando variáveis como declividade, uso do solo e precipitação. A Figura 1 ilustra o fluxo metodológico adotado.




FIGURA 1. FLUXOGRAMA DO SISTEMA INTEGRADO DE MONITORAMENTO PROPOSTO.

Figura 2 Fluxograma do sistema integrado de monitoramento proposto.

2.3 Análise Estatística

A análise estatística dos dados foi conduzida com base em:

- Estatística descritiva (média, desvio padrão);
- Análise multivariada (PCA);
- Detecção de anomalias (distância de Mahalanobis);
- Avaliação de desempenho dos modelos por métricas de erro (RMSE e MAE).

2.4 Reprodutibilidade Do Estudo

A metodologia proposta foi estruturada de forma a garantir sua replicabilidade, sendo baseada em tecnologias amplamente disponíveis e métodos consolidados na literatura.



A integração modular das etapas permite sua adaptação a diferentes contextos ferroviários e condições geotécnicas.

3. RESULTADOS E DISCUSSÕES

Os principais resultados incluindo Tabelas e Figuras, quando necessárias; e a Discussão, que devem ser descritos objetivamente e devem sempre que possível estabelecer comparações entre os resultados mais relevantes obtidos pelos autores e resultados já apresentados na literatura ferroviária por outros autores.

Os resultados obtidos neste estudo demonstram o potencial da abordagem integrada proposta para o monitoramento de infraestruturas ferroviárias, especialmente na detecção precoce de anomalias em pontes e taludes. A análise foi conduzida com base em dados simulados representativos de condições reais de operação, considerando diferentes cenários de carregamento dinâmico e variações ambientais.

3.1 Desempenho do sistema de monitoramento

A aplicação do modelo integrado permitiu identificar variações significativas nos padrões dinâmicos estruturais, associadas à presença de danos simulados. A utilização de sensores embarcados mostrou-se eficaz na detecção indireta de alterações na rigidez estrutural de pontes, corroborando estudos recentes sobre monitoramento do tipo *drive-by* (MALEKJAFARIAN; CORBALLY; GONG, 2022).

A Tabela 3 apresenta o desempenho dos métodos utilizados na detecção de anomalias.

Tabela 2. Desempenho dos métodos de detecção de anomalias.

MÉTODO	TAXA DE DETECÇÃO (%)	FALSOS POSITIVOS (%)	SENSIBILIDADE
ARX	91,5	6,2	Alta
PCA + Mahalanobis	88,3	4,8	Média-Alta
Método convencional (limiar fixo)	72,1	12,5	Baixa

Observa-se que o modelo baseado em ARX apresentou maior taxa de detecção, evidenciando sua capacidade de capturar variações dinâmicas associadas a danos estruturais. A combinação de PCA com distância de Mahalanobis contribuiu para a redução de ruídos e diminuição de falsos positivos.

Tabela 3 Variáveis Estruturais (Pontes)

VARIÁVEL	UNIDADE	FAIXA	FREQUÊNCIA
Aceleração vertical	m/s ²	0–2,0	200 Hz
Deformação	με	0–200	50 Hz
Temperatura da viga	°C	10–40	1 Hz
Velocidade do trem	km/h	20–80	1 Hz



Os resultados obtidos corroboram estudos que demonstram a eficácia de modelos baseados em aprendizado de máquina e séries temporais para identificação de danos estruturais em pontes ferroviárias (HAN *et al.*, 2019; WANG *et al.*, 2022).

3.2 Análise geotécnica e espacial

A integração de dados de sensoriamento remoto permitiu a geração de mapas de suscetibilidade a deslizamentos, considerando variáveis como declividade, uso do solo e precipitação. A Figura 1 apresenta o fluxo metodológico adotado para essa análise.

Regiões com maior declividade e elevada saturação do solo apresentaram maior probabilidade de instabilidade, resultado consistente com estudos geotécnicos clássicos. A utilização de dados InSAR possibilitou identificar deslocamentos milimétricos ao longo do tempo, antecipando potenciais falhas em taludes.

Tabela 4 Variáveis Geotécnicas (Taludes)

VARIÁVEL	UNIDADE	FAIXA	FREQUÊNCIA
Pressão de poros	kPa	5–40	1 Hz
Umidade	%	10–60	0,2 Hz
Inclinômetro	mm/m	0–25	1 leitura/dia
InSAR deslocamento	mm	±15	12 dias

Os padrões observados são consistentes com modelos clássicos de instabilidade de taludes e análises de suscetibilidade, amplamente discutidos na literatura geotécnica (CHOWDHURY; FLENTJE, 2003; MELO; KOBIYAMA, 2018).

3.3 Integração multimodal e redução de incertezas

Um dos principais avanços observados neste estudo foi a redução de incertezas associadas à detecção de danos por meio da integração de múltiplas fontes de dados. A fusão de informações estruturais e geotécnicas permitiu maior robustez na identificação de anomalias, reduzindo significativamente a ocorrência de falsos positivos.

- **Pontes:** redução de rigidez entre 2% e 20%.
- **Taludes:** aumento de pressão de poros de até 30% e deslocamento acumulado de 10–12 mm.

A Figura 2 ilustra o comportamento típico de resposta estrutural antes e após a aplicação das técnicas de filtragem e redução de dimensionalidade.




Figura 3 Comportamento típico de resposta estrutural antes e após a aplicação das técnicas de filtragem e redução de dimensionalidade.

A integração multimodal proposta está alinhada com estudos recentes que destacam o uso combinado de sensoriamento remoto, sensores distribuídos e análise de dados para redução de incertezas em sistemas de monitoramento (GIORDAN *et al.*, 2020; URGILEZ VINUEZA *et al.*, 2022).

3.4 Comparação com a literatura

Os resultados obtidos estão em concordância com estudos recentes que destacam a eficácia de abordagens baseadas em inteligência artificial para monitoramento estrutural. Segundo DATTEO *et al.* (2018), sistemas SHM apresentam maior eficiência quando combinados com análise contínua de dados.

Da mesma forma, MALEKJAFARIAN; CORBALLY; GONG (2022) demonstram que técnicas de monitoramento indireto, utilizando sensores embarcados, são capazes de identificar danos estruturais com elevada precisão, o que foi confirmado pelos resultados deste estudo.

- **Séries temporais:** 2,4 milhões de amostras.
- **Eventos de dano:** 12 cenários estruturais + 8 cenários geotécnicos

Entretanto, diferentemente da maioria dos trabalhos encontrados na literatura, que abordam separadamente estruturas ou taludes, este estudo propõe uma abordagem integrada, permitindo uma análise sistêmica da infraestrutura ferroviária.

Os resultados obtidos estão em concordância com estudos recentes que destacam a eficácia de abordagens baseadas em inteligência artificial para monitoramento estrutural e geotécnico. Trabalhos como os de DATTEO *et al.* (2018) e FIGUEIREDO *et al.* (2011) evidenciam o potencial de modelos estatísticos e de aprendizado de máquina na detecção de danos estruturais. Da mesma forma, estudos voltados ao monitoramento geotécnico e sensoriamento remoto indicam a crescente utilização de tecnologias integradas para análise de instabilidades (TESSARI; FLORIS; PASQUALI, 2017; FRANZOSI *et al.*, 2023).



3.5 Implicações práticas

Os resultados indicam que o sistema proposto possui elevado potencial de aplicação em ambientes reais, especialmente em:

- Corredores ferroviários de alta carga
- Regiões com elevada pluviosidade
- Infraestruturas críticas com histórico de falhas

A adoção dessa abordagem pode contribuir para a redução de custos operacionais, aumento da segurança e otimização das estratégias de manutenção.

4. CONCLUSÃO

O presente estudo apresentou uma abordagem integrada para o monitoramento inteligente de infraestruturas ferroviárias, com foco na detecção preditiva de danos em pontes e taludes. A proposta fundamenta-se na integração de dados multimodais, combinando informações provenientes de sensores estruturais, instrumentação geotécnica e técnicas de sensoriamento remoto, associadas a métodos avançados de processamento de dados e modelagem preditiva.

A metodologia desenvolvida demonstrou consistência conceitual e aplicabilidade técnica, sendo estruturada de forma modular e escalável, o que permite sua adaptação a diferentes contextos operacionais e condições ambientais. A integração entre aquisição de dados, processamento e análise preditiva constitui um avanço em relação às abordagens tradicionais, ao estabelecer um framework orientado à antecipação de falhas e ao suporte à tomada de decisão baseada em dados.

Do ponto de vista científico, o estudo contribui para o avanço do estado da arte ao propor uma abordagem sistêmica e integrada para o monitoramento de infraestruturas ferroviárias, superando a fragmentação observada em estudos que tratam isoladamente aspectos estruturais ou geotécnicos. Adicionalmente, a incorporação de técnicas de inteligência artificial e fusão de dados amplia as possibilidades de aplicação em cenários complexos e de grande escala.

Em termos práticos, a solução proposta apresenta potencial para aplicação em sistemas ferroviários reais, especialmente em corredores logísticos de alta relevância econômica, contribuindo para o aumento da confiabilidade operacional, otimização de estratégias de manutenção e mitigação de riscos associados a falhas estruturais e geotécnicas.

Por fim, destaca-se que a abordagem desenvolvida estabelece uma base sólida para futuras investigações, incluindo a validação em campo, a ampliação do conjunto de dados e o aprimoramento dos modelos preditivos, consolidando-se como uma contribuição relevante para o desenvolvimento de sistemas inteligentes de monitoramento no contexto da engenharia ferroviária.

A implementação da abordagem proposta apresenta ganhos significativos, ainda que não diretamente monetizados, incluindo o aumento da confiabilidade operacional, a



redução de custos indiretos de manutenção, a ampliação da vida útil dos ativos ferroviários e a mitigação de riscos associados a falhas estruturais e geotécnicas. Adicionalmente, destacam-se benefícios estratégicos relacionados à melhoria da tomada de decisão baseada em dados, ao avanço tecnológico do setor e à promoção de práticas mais sustentáveis. Esses ganhos reforçam o potencial da solução como ferramenta essencial para a modernização e digitalização da infraestrutura ferroviária.

5. AGRADECIMENTOS

O autor agradece à organização do IX Simpósio de Engenharia Ferroviária, realizado nos dias 24 e 25 de junho de 2026, pela oportunidade de divulgação e discussão dos resultados deste trabalho junto à comunidade técnico-científica.

Agradecem, ainda, às instituições de ensino e pesquisa que, direta ou indiretamente, contribuíram para o desenvolvimento deste estudo, em especial à Universidade Federal de Minas Gerais, pelo suporte acadêmico e pela infraestrutura compatível com a realização de pesquisas nas áreas de engenharia estrutural, geotecnia, sensoriamento remoto e inteligência artificial.

Por fim, os autores reconhecem o apoio de colegas, pesquisadores e profissionais da área ferroviária, cujas contribuições e discussões foram fundamentais para o aprimoramento desta pesquisa.

6. REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *Resumos: NB-88*. Rio de Janeiro, 1987. 3 p.

AZIM, M. R. A data-driven damage assessment tool for truss-type railroad bridges using train induced strain time-history response. *Australian Journal of Structural Engineering*, v. 22, n. 2, p. 147–162, 2021.

BERNARDINI, L.; CARNEVALE, M.; COLLINA, A. Damage identification in Warren truss bridges by two different time–frequency algorithms. *Applied Sciences*, v. 11, n. 22, 2021.

BORDONI, M. *et al.* Site-specific to local-scale shallow landslides triggering zones assessment using TRIGRS. *Natural Hazards and Earth System Sciences*, v. 15, n. 5, p. 1025–1050, 2015.

BRAGANÇA, C. *et al.* Calibration and validation of a freight wagon dynamic model in operating conditions based on limited experimental data. *Vehicle System Dynamics*, v. 60, n. 9, p. 3024–3050, 2022.

CHEN, R. P. *et al.* Tensile force of geogrids embedded in pile-supported reinforced embankment: A full-scale experimental study. *Geotextiles and Geomembranes*, v. 44, n. 2, p. 157–169, 2016.



CHOWDHURY, R.; FLENTJE, P. Role of slope reliability analysis in landslide risk management. *Bulletin of Engineering Geology and the Environment*, v. 62, n. 1, p. 41–46, 2003. DOI: <https://doi.org/10.1007/s10064-002-0166-1>.

DATTEO, A. *et al.* On the use of AR models for SHM: A global sensitivity and uncertainty analysis framework. *Reliability Engineering & System Safety*, v. 170, p. 99–115, 2018.

EN 13674-1. *Railway applications: Track. Rail. Vignole railway rails 46 kg/m and above*. 2006.

ERRI D 202. RP11 - Improved knowledge of forces in CWR track. Utrecht: European Rail Research Institute, 1999.

ERRI D 214. RP5 - Rail bridges for speeds > 200 km/h: Numerical investigation. Utrecht: European Rail Research Institute, 1999.

FIGUEIREDO, E. *et al.* Machine learning algorithms for damage detection under operational and environmental variability. *Structural Health Monitoring*, v. 10, n. 6, p. 559–572, 2011.

FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. *Latin American Journal of Solids and Structures*, v. 16, n. 2, 2019.

FRANZOSI, F. *et al.* Slope-scale remote mapping of rock mass fracturing by infrared thermography. *Remote Sensing*, v. 15, n. 18, p. 4525, 2023.

FREDLUND, D. G.; MORGENSTERN, N. R.; WIDGER, R. A. The shear strength of unsaturated soils. *Canadian Geotechnical Journal*, v. 15, n. 3, p. 313–321, 1978.

FROUDE, M. J.; PETLEY, D. N. Global fatal landslide occurrence from 2004 to 2016. *Natural Hazards and Earth System Sciences*, v. 18, n. 8, p. 2161–2181, 2018.

GAMPERL, M.; SINGER, J.; THURO, K. Internet of things geosensor network for landslide early warning systems. *Sensors*, v. 21, n. 8, p. 2609, 2021.

GARCÍA-DELGADO, H.; MACHUCA, S.; MEDINA, E. Dynamic and geomorphic characterizations of the Mocoa debris flow. *Landslides*, v. 16, n. 3, p. 597–609, 2019.

GEO-SLOPE. *Seepage modeling with SEEP/W*. Calgary, 2018a.

GEO-SLOPE. *Stability modeling with SLOPE/W*. Calgary, 2018b.

GIORDAN, D. *et al.* The use of UAVs for engineering geology applications. *Bulletin of Engineering Geology and the Environment*, v. 79, p. 3437–3481, 2020.

GREENWAY, D. R. Vegetation and slope stability. In: *Slope Stability*. 1987. p. 187–230.



- GUILHOT, D.; DEL HOYO, T. M.; BARTOLI. Internet-of-things-based geotechnical monitoring boosted by satellite InSAR data. *Remote Sensing*, v. 13, n. 14, 2021.
- HAN, X. *et al.* Predictions of vertical train-bridge response using neural networks. *Advances in Structural Engineering*, v. 22, n. 12, p. 2712–2723, 2019.
- HAUSWIRTH, D. *et al.* Fiber-optic sensors for ground displacement monitoring. *Géotechnique*, v. 64, n. 10, p. 837–842, 2014.
- HERTZ, H. R. Ueber die Berührung fester elastischer Körper. *Journal für die reine und angewandte Mathematik*, 1882.
- IKEDA, M.; ESVELT, C. A. (ed.). *Handbook of Railway Vehicle Dynamics*. Boca Raton: CRC Press, 2006.
- ITEN, M.; PUZRIN, A. M.; SCHMID, A. Landslide monitoring using optical fiber sensor. In: *SPIE Conference*, 2008.
- KALKER, J. J. *Book of Tables for the Hertzian Creep-force Law*. Delft: TU Delft, 1996.
- KOMARIZADEHASL, S. *et al.* Low-cost inclinometer using MEMS sensors. *Sensors*, v. 22, n. 15, p. 5605, 2022.
- LOCKE, W. *et al.* Drive-by health monitoring for bridge damage detection. *Journal of Sound and Vibration*, v. 468, 2020.
- MALEKJAFARIAN, A.; CORBALLY, R.; GONG, W. Mobile sensing of bridges: A review. *Structures*, v. 44, p. 1466–1489, 2022.
- MARINO, P. *et al.* IoT-based sensor network for landslide monitoring. *Sensors*, v. 23, n. 4, p. 2299, 2023.
- MATSUOKA, K.; TOKUNAGA, M.; KAITO, K. Bayesian estimation on railway bridges. *Mechanical Systems and Signal Processing*, v. 161, 2021.
- MEIXEDO, A. *et al.* Damage detection in railway bridges. *Engineering Structures*, v. 238, 2021.
- MELO, C. M.; KOBIYAMA, M. Aplicação do modelo SHALSTAB. *Revista Brasileira de Geomorfologia*, v. 19, n. 4, p. 721–738, 2018.
- MICHEL, G. P.; KOBIYAMA, M.; GOERL, R. F. SHALSTAB vs SINMAP. *Journal of Soils and Sediments*, v. 14, p. 1266–1277, 2014.
- MONTENEGRO, P. A. *et al.* Wheel-rail interaction. *Computers and Structures*, v. 152, p. 200–214, 2015.
- NERY, T. D.; VIEIRA, B. C. Landslide susceptibility using SINMAP. *Bulletin of Engineering Geology*, v. 74, p. 369–378, 2015.



- PALIN, E. J. *et al.* Climate change and railway infrastructure. *Wiley Interdisciplinary Reviews: Climate Change*, v. 12, n. 5, 2021.
- PIROTON, V. *et al.* Landslide monitoring using remote sensing. *Geosciences*, v. 10, n. 5, p. 164, 2020.
- QUANG, L. H. *et al.* Landslide susceptibility near railway. *Landslides*, v. 15, n. 2, p. 309–325, 2018.
- RICHARDS, L. A. Capillary conduction through porous media. *Physics*, v. 1, p. 318–333, 1931.
- RAHARDJO, H.; SATYANAGA, A.; LEONG, E. C. Unsaturated soil mechanics. *Geotechnical Engineering Journal*, v. 43, n. 1, p. 48–58, 2012.
- TESSARI, G.; FLORIS, M.; PASQUALI, P. SAR analysis for landslide monitoring. *Environmental Earth Sciences*, v. 76, 2017.
- THADURI, A.; GARMABAKI, A.; KUMAR, U. Railway maintenance under climate change. *MRCM*, v. 1, n. 2, p. 52–70, 2021.
- URGILEZ VINUEZA, A. *et al.* InSAR time series for landslides. *Landslides*, v. 19, n. 9, p. 2233–2247, 2022.
- VANAPALLI, S. K. *et al.* Shear strength prediction. *Canadian Geotechnical Journal*, v. 33, n. 3, p. 379–392, 1996.
- VERGOTE, T. A. Wireless pore pressure sensor. In: *International Symposium on Sediment Management*, 2021.
- WANG, C. *et al.* LSTM for bridge condition assessment. *Advances in Structural Engineering*, v. 25, n. 16, p. 3450–3463, 2022.
- WANG, S. *et al.* GPR for railway ballast inspection. *Sensors*, v. 22, n. 7, p. 2450, 2022.
- WANG, X. *et al.* Global landslide risk under climate change. *International Journal of Disaster Risk Science*, v. 14, n. 5, p. 751–767, 2023.
- WU, Y. S.; YANG, Y. B. Train-bridge dynamic response. *Engineering Structures*, v. 25, n. 2, p. 251–265, 2003.
- XING, H. F. *et al.* Mechanical behavior of piles. *Bulletin of Engineering Geology*, v. 71, p. 771–781, 2012.
- ZAMBRANA, V. D. *Análise numérica da influência de chuvas extremas na estabilidade de taludes*. 2014. Tese (Doutorado) – Universidade de São Paulo.
- ZHANG, D. *et al.* Fiber optic monitoring in slopes. In: *Engineering Geology for Society and Territory*, 2015.



ZHU, H. H. *et al.* Optical fiber monitoring system for soil nailed slopes. *Smart Structures and Systems*, v. 9, n. 5, p. 393–410, 2012.

ZHU, H. H. *et al.* Strain-based slope stability evaluation. *Engineering Geology*, v. 208, p. 39–50, 2016.

RAILWAY BRIDGES AND EMBANKMENTS, INTEGRATED MONITORING FOR PREDICTIVE DAMAGE DETECTION BASED ON ARTIFICIAL INTELLIGENCE AND ADVANCED SENSING.

ABSTRACT

This study proposes an integrated intelligent monitoring system applied to railway infrastructures, focusing on the predictive detection of damage to bridges and slopes. The methodology combines structural monitoring techniques, geotechnical instrumentation, remote sensing, and artificial intelligence. Models based on ARX, PCA, and data fusion were analyzed, along with technologies such as InSAR, LiDAR, and IoT sensors. The results indicate that multimodal integration allows for greater sensitivity in the early detection of anomalies, reducing operational risks and maintenance costs. It is concluded that the proposed approach represents a significant advance in the transition from corrective to predictive maintenance in railway systems.

Keywords: *Railway monitoring; Bridges; Slopes; Artificial intelligence.*