



PEC PUBLICAÇÕES

Organizadores

Julia Castro Mendes,
Alexandre Abrahão Cury,
Flávio de Souza Barbosa,
Aldo Ribeiro de Carvalho
e Vitor Freitas Mendes

INTELIGÊNCIA ARTIFICIAL APLICADA À ENGENHARIA:

primeiros passos
e aplicações



EDITORA
U F J F

Organizadores

Julia Castro Mendes,
Alexandre Abrahão Cury,
Flávio de Souza Barbosa,
Aldo Ribeiro de Carvalho e
Vitor Freitas Mendes

INTELIGÊNCIA ARTIFICIAL APLICADA À ENGENHARIA: PRIMEIROS PASSOS E APLICAÇÕES



JUIZ DE FORA

2025

© 2025 Editora UFJF

Licença Creative Commons CC BY-NC-ND 4.0 Deed. Você pode compartilhar o material, respeitando os termos a seguir: conceda o devido crédito, inclua um link para a licença e sinalize quaisquer alterações realizadas; é proibido o uso do material para fins comerciais; caso remixe, transforme ou crie a partir do material original, fica vedada a distribuição da versão modificada.



Reitor(a): Girlene Alves da Silva

Vice-reitor(a): Telmo Mota Ronzani

Pró-reitor(a) de Pós-graduação e Pesquisa: Priscila de Faria Pinto

Pró-reitor(a) Adjunta de Pós-graduação e Pesquisa: Isabel Cristina Gonçalves Leite

Membros internos:

Prof. Flavio de Souza Barbosa (Presidente do Conselho)

Prof. Pedro Kopschitz Xavier Bastos

Prof. Edgard Henrique Oliveira Dias



Membro externos:

Profa. Aline Calazans Marques – Universidade Federal do Rio de Janeiro (UFRJ)

Prof. Raphael Correa Medeiros – Universidade Federal de Santa Maria (UFSM)

Prof. Hernan Garrido – Universidad Nacional de Cuyo (Argentina)

Revisão de português : Fator Gestão

Revisão de normas técnicas: Fator Gestão

Capa e projeto gráfico: Fator Gestão

Diagramação: Fator Gestão

Crédito da imagem da capa: Freepik

Fontes utilizadas: Calibri e Montserat TT

Catalogação de Publicação na Fonte. Sistema de Bibliotecas (SisBi) - UFJF

Inteligência artificial aplicada à Engenharia : primeiros passos e aplicações / Júlia castro Mendes (Org.) ... [et al.]. – Juiz de Fora: Editora UFJF, 2025.
256 p.: il.

ISBN 978-65-85363-02-0

1. Inteligência artificial. 2. Aprendizagem de máquina. 3. Aprendizado profundo. 4. Otimização multiobjetivo. 5. Engenharia assistida por dados. I. Mendes, Julia Castro (org.). II. Cury, Alexandre Abrahão (org.). III. Barbosa, Flávio de Souza (org.). IV. Carvalho, Aldo Ribeiro de (org.). V. Mendes, Vitor Freitas (org.). VI. Título.

CDU: 007.52:62

Bibliotecário responsável: Eliane Silva de Sousa - CRB-6 2008



Editora UFJF – Pró-reitoria de Pós-Graduação e Pesquisa

Campus Universitário, bairro São Pedro – Juiz de Fora, MG,

Brasil – CEP 36036-900

editora@ufjf.br / propp@ufjf.br



SUMÁRIO

Prefácio	5
Prof. Rodrigo Weber dos Santos	
Apresentação	7
1 Inteligência Artificial aplicada à Engenharia: principais conceitos e definições	9
2 Predição do preço de imóveis por meio do aprendizado de máquina: uma revisão sistemática da literatura	86
3 Inteligência Artificial aplicada a compósitos geopoliméricos: uma revisão sistemática da literatura	108
4 Influência da heterogeneidade dos bancos de dados na dosagem de concretos por meio de Aprendizado de Máquina	133
5 Processamento de imagens aplicado ao monitoramento de integridade estrutural	145
6 Aprendizado de Máquina para o monitoramento da integridade de paredes utilizando smartphones	163
7 Avaliação de danos estruturais utilizando otimização inteira mista via classificação	179
8 Autocodificadores e suas diferentes aplicações na Engenharia	193
9 Detecção de cargas desbalanceadas em vagões ferroviários de carga via aprendizagem de máquina	211
10 Aplicação do Método das Somas Ponderadas e Otimização Multiobjetivo em análise estrutural usando Computação Evolucionária	230
11 Técnicas de Inteligência Computacional aplicadas a problemas inversos em engenharia de estruturas	243

PREFÁCIO

Prof. Rodrigo Weber dos Santos¹

¹Departamento de Ciência de Computação / Programa de Pós Graduação em Modelagem Computacional / UFJF

Ao longo da história, a Engenharia sempre se baseou em fundamentos físicos, experimentação sistemática e normas técnicas para desenvolver soluções robustas e confiáveis. A engenharia clássica consolidou-se a partir de modelos mecanicistas, validados empiricamente e fundamentados em leis físicas bem estabelecidas. Essa abordagem permitiu avanços extraordinários em todas as áreas do conhecimento aplicado, proporcionando segurança, eficiência e previsibilidade nas construções, nos materiais e nos sistemas estruturais. Entretanto, com o crescimento exponencial da disponibilidade de dados e o avanço das capacidades computacionais, uma nova fronteira vem sendo explorada: os modelos baseados em dados. Impulsionada pela Inteligência Artificial (IA), essa abordagem moderna permite extrair padrões e inferências diretamente de grandes volumes de informações, sem necessariamente depender de um modelo físico explícito. Essa mudança de paradigma vem complementando as abordagens tradicionais, abrindo espaço para soluções mais adaptativas, personalizadas e automatizadas.

A Inteligência Artificial (IA) tem se consolidado como uma tecnologia transformadora da engenharia moderna. Este livro oferece um panorama abrangente sobre como a IA está sendo incorporada a diferentes domínios da Engenharia, fornecendo aos leitores os fundamentos e aplicações práticas dessa tecnologia. Ao longo dos capítulos, os autores exploram os principais conceitos de IA e aprendizado de máquina, destacando técnicas essenciais para o tratamento de dados, construção e validação de modelos. O aprendizado supervisionado e o não supervisionado são apresentados de forma didática, permitindo que engenheiros e cientistas compreendam como essas abordagens podem ser aplicadas na solução de problemas reais. Além disso, aspectos fundamentais como a redução de dimensionalidade e a avaliação de desempenho dos modelos também são apresentados.

O livro também traz aplicações práticas da IA em diferentes áreas da Engenharia. Um dos capítulos examina como o aprendizado de máquina pode aprimorar a dosagem de concretos, superando limitações dos métodos empíricos tradicionais. Outro estudo detalha a aplicação de algoritmos de otimização multiobjetivo no projeto estrutural,

combinando métodos heurísticos com o Método dos Elementos Finitos para alcançar soluções mais eficientes. A precificação de imóveis é outro exemplo de aplicação explorado, demonstrando como modelos de aprendizado de máquina podem captar tendências do mercado e fornecer estimativas mais precisas dos valores de venda. A Inteligência Artificial também tem mostrado grande potencial na engenharia de materiais, como ilustrado em uma revisão sobre o uso de IA para prever propriedades de compósitos geopoliméricos. Esse novo campo abre novas possibilidades para o desenvolvimento de materiais mais sustentáveis e eficientes. Da mesma forma, o monitoramento de integridade estrutural utilizando processamento de imagens evidencia como a IA pode ser empregada para detectar patologias estruturais precocemente, reduzindo custos de manutenção e aumentando a segurança das edificações. Outro estudo relevante, abordado na obra, é a detecção de cargas desbalanceadas em vagões ferroviários, onde técnicas avançadas de aprendizado de máquina são aplicadas para analisar respostas dinâmicas dos trilhos e prever desequilíbrios transversais. Esse tipo de abordagem tem o potencial de prevenir acidentes e otimizar a manutenção da infraestrutura ferroviária.

Além dos avanços tecnológicos, o livro também discute desafios e limitações da IA na Engenharia. A variabilidade dos dados, o risco de *overfitting* e a necessidade de validação rigorosa dos modelos são aspectos críticos que devem ser considerados ao aplicar essas ferramentas. Os autores enfatizam a importância da qualidade dos dados e do uso responsável da IA. Ao unir fundamentos teóricos a estudos de caso práticos, esta obra se torna uma excelente referência para engenheiros, pesquisadores e estudantes que procuram uma porta de entrada à fascinante área de IA na engenharia civil.

APRESENTAÇÃO

A ideia deste livro nasceu em um momento de incertezas e transformações. Durante a pandemia da Covid-19, quando os laboratórios foram fechados e os projetos experimentais precisaram ser interrompidos, muitos pesquisadores e pesquisadoras se viram diante do desafio de reinventar seus caminhos acadêmicos dentro de suas próprias casas. Nesse contexto, o uso da Inteligência Artificial (IA) chamou a atenção como uma solução promissora para dar continuidade às pesquisas.

Era uma área nova para muitos de nós, cheia de possibilidades ainda pouco exploradas na engenharia. Mas, ao mesmo tempo, sentimos falta de um ponto de partida — de um material acessível, didático, que ajudasse a entender o básico e abrir caminhos. Foi nesse desejo de aprender e compartilhar que a ideia deste livro começou a ganhar forma. Reunimos, então, um grupo diverso de professores, professoras, pós-graduandos e pós-graduandas com diferentes formações, mas um objetivo comum: aplicar técnicas de aprendizado de máquina, aprendizado profundo e inteligência computacional para enfrentar problemas reais da engenharia.

Os capítulos aqui apresentados são frutos de investigações que extrapolaram os limites impostos pela pandemia e amadureceram como projetos consistentes de pesquisa. Esses trabalhos, inclusive, inspiraram a criação do CIDENG – Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia (@cidengcnpq), que hoje, reúne pesquisadores(as) de diferentes instituições atuando nas áreas de Construção Civil, Eficiência Energética, Monitoramento de Estruturas e Mecânica das Estruturas, com o propósito de contribuir para uma engenharia mais ética, inteligente e eficiente.

Este livro foi pensado com muito cuidado para ser uma ferramenta útil, inspiradora e acolhedora para quem está começando. O primeiro capítulo, “Inteligência Artificial aplicada à Engenharia: principais conceitos e definições”, cumpre justamente esse papel: apresentar os fundamentos da IA de forma clara, acessível e aplicada, oferecendo uma base sólida para a leitura dos demais capítulos.

A obra segue com estudos de caso e revisões sistemáticas. Na construção civil, os temas incluem a predição de preços de imóveis, a aplicação de IA em compósitos geopoliméricos e a análise do impacto da heterogeneidade de dados na dosagem de concretos. Avançamos para aplicações práticas em monitoramento estrutural, como o uso de imagens e sensores, bem como abordagens de classificação para avaliação de danos estruturais. Também discutimos o uso de autocodificadores em

diferentes contextos, técnicas para detecção de falhas em sistemas ferroviários, métodos de otimização multiobjetivo aplicados à análise estrutural, e finalizamos com estratégias de inteligência computacional voltadas à solução de problemas inversos em engenharia de estruturas.

Esperamos que esta leitura seja tão inspiradora quanto foi o processo de criação deste livro. Que ele possa abrir caminhos e despertar novas ideias. Boa leitura!

Julia Castro Mendes,
Alexandre Abrahão Cury,
Flávio de Souza Barbosa,
Aldo Ribeiro de Carvalho,
Vitor Freitas Mendes,
Organizadores

1 INTELIGÊNCIA ARTIFICIAL APLICADA À ENGENHARIA: PRINCIPAIS CONCEITOS E DEFINIÇÕES

Aldo Ribeiro de Carvalho¹, Vitor Freitas Mendes¹,
Anderson Ravik dos Santos¹, Carolina de Melo Nunes Lopes¹,
Nalberth Vicentin Santana¹, Nayara Mendes dos Santos¹,
Victor Higino Meneguitte Alves², Rivelino Neri Silva¹,
Letícia Matias Martins¹, Danielle Rios Garcia¹,
Alexandre Abrahão Cury², Julia Castro Mendes^{1,2}

¹ Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Ouro Preto, Brasil.

² Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Juiz de Fora, Brasil.

1.1 Resumo

Este capítulo apresenta alguns fundamentos da Inteligência Artificial (IA) e do Aprendizado de Máquina (AM) e Aprendizado Profundo (AP), destacando definições e conceitos essenciais, sem a pretensão de esgotar os temas abordados. São explorados os principais tipos de aprendizado, incluindo o supervisionado, que prevê saídas com base em exemplos rotulados, e o não supervisionado, voltado à identificação de padrões em dados não rotulados. O pré-processamento de dados é enfatizado como uma etapa crítica para a eficácia dos modelos, abrangendo técnicas como limpeza, normalização e transformação, além do tratamento de variáveis categóricas por meio de codificadores (*encoders*). A redução de dimensionalidade, com destaque para a Análise de Componentes Principais (PCA), é apresentada como estratégia para otimizar modelos ao reduzir a complexidade dos dados. Também são abordados os processos de validação de modelos, introduzindo métodos como a validação cruzada, fundamentais para garantir a capacidade de generalização. Além disso, são discutidas métricas de avaliação, como o coeficiente de correlação (R^2) e Erro Absoluto Percentual Médio (EAPM), essenciais para interpretar a precisão

dos modelos preditivos. Por fim, a seção 1.10 discute aspectos éticos da IA, incluindo vieses, transparência e impacto social, ressaltando a importância do uso responsável da tecnologia. De forma geral, este capítulo oferece uma visão introdutória das técnicas de IA mais adotadas em problemas de Engenharia, buscando embasar os primeiros passos de pesquisadores e pesquisadoras nessa área.

Palavras-Chave: Inteligência Artificial; Aprendizado de Máquina; Pré-processamento de Dados; Redução de Dimensionalidade; Validação de Modelos

1.2 Introdução

A Inteligência Artificial (IA), do inglês *Artificial Intelligence*, pode ser definida como um sistema capaz de interpretar dados externos, aprender a partir deles e utilizar o conhecimento adquirido para alcançar objetivos e realizar tarefas específicas. Em um sentido amplo, IA refere-se ao estudo e desenvolvimento de sistemas que buscam simular aspectos do pensamento e comportamento humano (Google Cloud, 2024). No entanto, essa definição é controversa, pois a IA não replica verdadeiramente a inteligência humana, uma vez que carece de consciência, raciocínio, emoções, adaptabilidade e habilidades generalistas de resolução de problemas. Assim, há um consenso crescente de que a IA deve ser entendida não como uma substituta da inteligência humana, mas como uma ferramenta para analisar padrões em dados e ampliar as capacidades humanas.

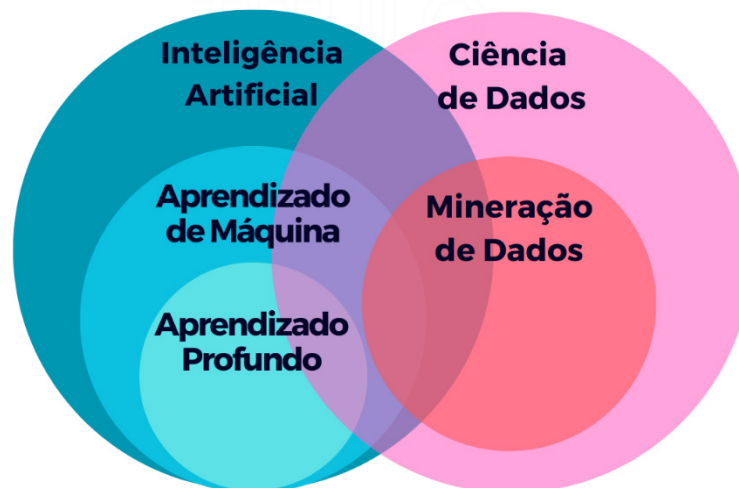
Na Engenharia, as principais funcionalidades da IA incluem a análise avançada de dados, automação de processos, otimização de sistemas e suporte à tomada de decisão. A IA permite o monitoramento contínuo de sistemas, facilitando a detecção de padrões e anomalias. Além disso, possibilita a modelagem e simulação de cenários complexos e a previsão de comportamentos, reduzindo custos e tempo de desenvolvimento de soluções. A IA também desempenha um papel essencial na integração de tecnologias emergentes, como Internet das Coisas (IoT), a manufatura aditiva e gêmeos digitais (*Digital Twins*), promovendo maior conectividade e automação em diferentes setores da engenharia.

A primeira parte deste capítulo (seção 1.3 a seguir) apresenta os conceitos fundamentais e termos técnicos da área de IA, a fim de facilitar a compreensão dos tópicos que serão abordados ao longo da obra. Nas seções seguintes, são apresentados o funcionamento de algoritmos de Aprendizado de Máquina (AM) e Aprendizado Profundo (AP). Por fim, o último tópico traz exemplos e diretrizes para a construção ética de algoritmos de IA.

1.3 Principais conceitos e passo a passo de um problema de AM e AP

Como toda área tecnológica, a IA possui uma terminologia própria, sendo relevante conhecer os principais termos e suas definições. Entre esses termos, destacam-se o Aprendizado de Máquina (AM, em inglês *Machine Learning*) e o Aprendizado Profundo (AP, em inglês *Deep Learning*), que estão interrelacionados, embora apresentem distinções importantes (Figura 1).

Figura 1 - Representação visual hierárquica dos principais conceitos relacionados à IA



Fonte: Autores.

O AM é uma subárea da IA que foca na programação de computadores para que aprendam a partir de dados, sem a necessidade de instruções explícitas. Em outras palavras, AM é um campo de estudo que capacita computadores a aprenderem com experiências, adaptando-se e melhorando seu desempenho de forma autônoma (Géron, 2019). Por fim, o AP é uma especialização dentro do AM que utiliza redes neurais artificiais com múltiplas camadas de processamento para extrair e representar informações de maneira hierárquica, visando identificar padrões complexos em grandes conjuntos de dados (Google Cloud, 2024).

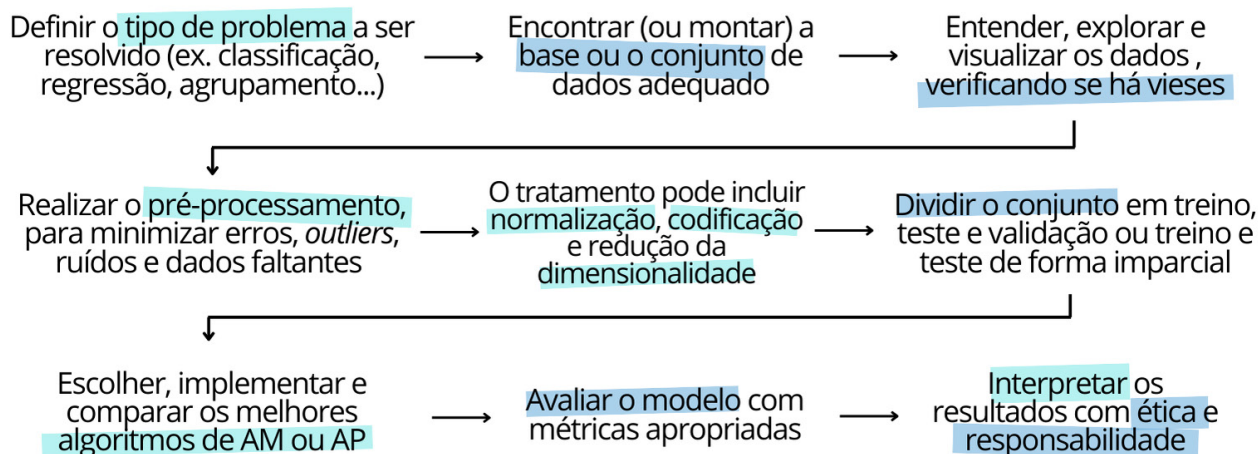
Esses campos possuem interseções com a Ciência de Dados (em inglês *Data Science*), que é um campo interdisciplinar que combina estatística, computação e conhecimento específico de domínio para extrair informações úteis de dados. Todas essas áreas utilizam técnicas estatísticas e matemáticas para análise de dados e modelagem preditiva, além de lidar com grandes conjuntos de dados (*Big Data*). Entretanto, embora tenham aplicações em comum, enquanto a Ciência de Dados se preocupa mais com a interpretação dos dados, IA e AM usam essas informações úteis para criar sistemas inteligentes.

A Mineração de Dados (*Data Mining*) é o processo de descoberta de padrões e de conhecimento em grandes volumes de dados. Ela está relacionada à Ciência

de Dados e à Estatística, e tem por objetivo a extração de informações úteis, identificando tendências, correlações e anomalias. A mineração de dados é mais exploratória e pode ser aplicada mesmo sem um modelo preditivo, sendo amplamente usada em *business intelligence*, análise de mercado e detecção de fraudes. A Mineração de Dados pode utilizar IA e AM como ferramentas para extrair conhecimento de dados, mas nem toda Mineração de Dados envolve IA, pois métodos estatísticos tradicionais também são amplamente utilizados.

A Figura 2 apresenta um fluxo simplificado para resolver problemas de engenharia com AM ou AP. A partir do sistema que o(a) pesquisador(a) quer modelar, o processo se inicia com a definição do tipo de problema. A seguir, deve-se buscar ou montar uma base de dados adequada; explorar os dados (evitando desequilíbrios e vieses); e realizar o pré-processamento, incluindo limpeza, integração, transformação e redução dos dados. Uma vez processados, os dados são divididos em treino, teste e validação, com estratégias específicas para garantir uma divisão justa e imparcial. Em seguida, testa-se diferentes algoritmos de AM e AP para identificar aquele que melhor se ajusta ao problema, avaliando seu desempenho com métricas apropriadas. Por fim, os resultados devem ser interpretados com ética e responsabilidade. Este livro não se aprofunda em técnicas específicas de AM e AP, pois são muitas e estão em constante evolução, mas oferece uma base conceitual sólida para quem está começando.

Figura 2 - Passo a passo simplificado do desenvolvimento de um problema de AM ou AP



Fonte: Autores.

1.3.1 Características

A maioria dos algoritmos de AM é estruturada com entradas e saídas definidas. As entradas, denominadas características (*features*), consistem em um conjunto de características que alimentam esses algoritmos. Quanto mais detalhadas e representativas forem essas características, maior será a capacidade

do algoritmo de identificar padrões nelas, sendo, portanto, um fator determinante para o sucesso do algoritmo (Baia, 2016) (Darmiton, 2020).

Um exemplo clássico de AM é o banco de dados de flores de Íris, de Ronald Fisher (1936), amplamente usado na classificação e no reconhecimento de padrões. Ele contém 50 amostras (ou observações ou instâncias) de cada uma das três espécies de Iris (Setosa, Versicolor e Virgínica) e mensura quatro características: comprimento e largura de sépalas e pétalas (Tabela 1). Esse banco de dados é utilizado por vários grupos de pesquisa para testar algoritmos para distinguir as espécies com base nessas características.

Tabela 1 - Representação do banco de dados de flores de Íris, desenvolvidos por Ronald Fisher

Obs.	Comprimento da sépala	Altura da sépala	Comprimento da pétala	Altura da pétala	Espécie
1	5,1	3,5	1,4	0,2	Setosa
2	7,0	3,2	4,7	1,4	Versicolor
3	6,4	3,2	4,5	1,5	Setosa
⋮	⋮	⋮	⋮	⋮	⋮
50	5,5	2,3	4,0	1,3	Versicolor

Fonte: (Fisher, 1936).

As principais abordagens para a obtenção de características são o método manual (*handcrafted features*) e a extração automática (*feature learning*). O método de manual se baseia na experiência de especialistas para recomendar um conjunto de características relevantes, um processo conhecido como engenharia de características (Darmiton, 2020). Esse procedimento geralmente é realizado de forma manual e está sujeito a erros, uma vez que depende diretamente da experiência do especialista, do conhecimento prévio sobre os dados, da área de aplicação, além de múltiplos testes para avaliar o desempenho do modelo com as características selecionadas (Ateliware, 2021).

Por outro lado, a extração automática permite automatizar essa tarefa, delegando ao próprio algoritmo a responsabilidade de identificar as características mais adequadas para a solução do problema. Nesse formato, as características são extraídas automaticamente dos dados brutos por algoritmos que buscam minimizar o erro global do sistema (Darmiton, 2020). O AP tem se destacado nesse contexto, especialmente em tarefas que envolvem processamento de imagens, reconhecimento de voz e análise de texto (Darmiton, 2020). Em diversas aplicações, a extração automática tem demonstrado resultados superiores em comparação ao método manual.

A eficácia dos algoritmos de IA depende diretamente da qualidade e representatividade das características extraídas dos dados. No entanto, na medida em que os volumes de dados crescem exponencialmente, a complexidade da seleção e do processamento dessas características também aumenta.

1.3.2 Big Data

O conceito de *Big Data* se refere ao grande volume de dados digitais que excede a capacidade humana de análise e que não pode ser processado por meio de ferramentas convencionais de processamento de dados (UNESCO, 2018). No caso de problemas de engenharia, pode-se citar os dados gerados por sensores, imagens, relatórios e artigos científicos, envolvendo grandes desafios para seu armazenamento, gerenciamento, compartilhamento e visualização (Sagiroglu Sinanc, 2013). A IA tem um papel essencial em transformar vastos conjuntos de dados em informações úteis para a tomada de decisões estratégicas (Silveira; Marcolin; Freitas, 2015).

As principais características da *Big Data* são geralmente resumidas nos chamados “7 V’s”, que definem a complexidade e o potencial deste conceito (Uddin; Gupta, 2014).

1. **Volume:** refere-se à grande quantidade de dados gerados e coletados que precisam ser analisados;
2. **Velocidade:** diz respeito à rapidez com que os dados são capturados e processados para fornecer informações úteis em tempo hábil;
3. **Vínculo:** envolve o entendimento das conexões entre diferentes conjuntos de dados, identificando como eles se relacionam e são hierarquizados;
4. **Variiedade:** relaciona-se aos diferentes tipos de dados gerados, sejam eles estruturados, semiestruturados ou não-estruturados (categorias definidas na próxima seção);
5. **Variabilidade:** refere-se à análise das mudanças nos padrões dos dados ao longo do tempo, considerando variáveis como sazonalidades e eventos excepcionais;
6. **Veracidade:** avalia a qualidade e a confiabilidade dos dados, assegurando que informações imprecisas ou irrelevantes sejam minimizadas;
7. **Visualização:** diz respeito à capacidade de organizar os dados de forma visual, utilizando gráficos, tabelas e outros esquemas, para facilitar a compreensão e a análise.

Para que esses dados possam ser utilizados em aplicações de IA, é fundamental estruturá-los de maneira acessível e interpretável. Nesse contexto, os

conjuntos de dados desempenham um papel central, pois servem como base para modelagens estatísticas e treinamentos de algoritmos.

1.3.3 Conjunto de Dados e Base de Dados

Uma base de dados é uma coleção organizada de informações geralmente armazenadas e acessadas eletronicamente por meio de sistemas informatizados, que permitem a manipulação, consulta e atualização eficiente dos dados (Sacramento, 2021). Um conjunto de dados é uma coleção estruturada de informações. A principal diferença entre base e conjunto de dados reside na escala e no propósito: enquanto os conjuntos de dados são amostras menores e focadas em um único tema para análise estatística ou treinamento de algoritmos, uma base de dados armazena diversos conjuntos de dados, que podem ou não estar relacionados entre si.

Os dados usados em aplicações de IA podem ser classificados de acordo com sua estrutura, dividindo-se em três categorias principais:

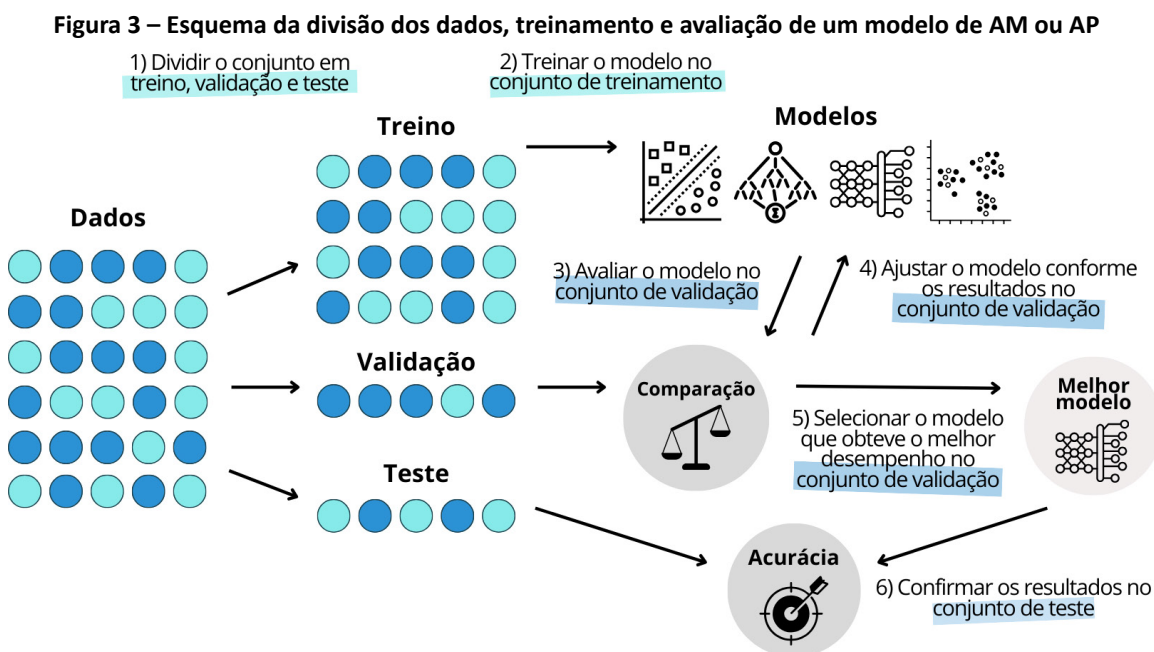
- a) **Estruturados:** dados organizados em bancos de dados tradicionais, apresentados em tabelas com linhas e colunas (ex.: da Tabela 1). Problemas de engenharia geralmente adotam bancos de dados estruturados;
- b) **Semiestruturados:** dados que seguem padrões heterogêneos, não obedecendo a um esquema fixo, mas contendo elementos que facilitam sua análise;
- c) **Não-estruturados:** dados provenientes de múltiplas fontes distintas, como vídeos, textos, áudios, imagens e arquivos XML.

No início de um projeto de AM ou AP, é essencial definir os conjuntos de dados mais adequados para a base de análise. Uma possibilidade é a criação de conjuntos de dados originais, a partir de ensaios laboratoriais, medições em campo ou sensores embarcados, como acelerômetros, termômetros, câmeras e dispositivos IoT. Esse tipo de base é especialmente valioso por refletir diretamente o contexto experimental e as condições reais da aplicação. Outra estratégia é a utilização de bases públicas já consolidadas, disponíveis em repositórios *online* (ex.: Github, Kaggle, The Algorithm, OpenML), plataformas governamentais (Portal de Dados Abertos, INEP e IBGE) ou plataformas acadêmicas (Zenodo; UCI Machine Learning Repository). Também é comum que pesquisadores(as) estruturam novas bases a partir do agrupamento e padronização de dados dispersos na literatura científica, como artigos, dissertações e relatórios técnicos. A escolha entre coletar ou reutilizar dados depende dos objetivos do estudo, da disponibilidade de recursos e da especificidade do problema.

1.3.4 Treino, teste e validação

A Figura 3 mostra um esquema do tratamento de dados no desenvolvimento de um modelo de AM ou AP. O processo geralmente se inicia com a divisão do banco de dados em três conjuntos: treino, validação e teste. O conjunto de treino é usado para construir o modelo, ou seja, é a base que permite aos algoritmos aprenderem os padrões. Por isso, para um bom aprendizado, o banco de dados de treino deve ser representativo do problema em questão, possuir um tamanho adequado e um equilíbrio entre as diferentes categorias (Paixão et al., 2022; Penido et al., 2022; Lopes; Mendes, 2023). O conjunto de validação compara modelos e hiperparâmetros, ajudando a qualificar o desempenho. Já o conjunto de teste avalia, de forma imparcial, a capacidade do modelo ajustado de lidar com dados não utilizados no treinamento (Suniga, 2020). Os dados desse conjunto não devem ser usados durante o treino e a validação, pois isso caracteriza vazamento de dados (abordado na seção 1.10.2, sobre Ética e IA).

Por exemplo, em um modelo para prever a resistência à compressão de concretos, atributos como a quantidade de cimento, agregados, água e aditivos são os parâmetros de entrada mais comuns. Para cada instância, cada conjunto de componentes (entrada), sabe-se a resistência à compressão correspondente (saída). O modelo é então treinado com dados de treino e aperfeiçoado com o conjunto de validação, para otimizar parâmetros e métodos. Por fim, seu desempenho final (correlação entre os resultados preditos pelo modelo e os valores reais constantes no banco de dados) é avaliado imparcialmente com o conjunto de teste.



A proporção de divisão das instâncias ou observações depende da sua quantidade e do tipo problema, sendo comum a separação aleatória em 80%-10%-10% ou 70%-15%-15% para treino, validação e teste, respectivamente (Muraina, 2022). Em alguns casos, a divisão é feita somente em treino e teste (geralmente 80%/20% ou 70%/30%) ou é feita de forma não-aleatória (buscando representatividade de todas as categorias em cada conjunto). Uma maior alocação para o treino é desejável para garantir um bom aprendizado do modelo (Cosenza, 2015).

Caso a divisão dos dados entre esses três conjuntos ocorra de forma inadequada (por exemplo, uma dada classe fica mais representada no conjunto de teste do que no de treino), isso pode levar o modelo a apresentar um baixo desempenho (subajuste, seção 1.10.2). Em casos específicos em que instâncias muito próximas estejam distribuídas no conjunto de treino e de teste, o modelo pode somente repetir o valor de saída sem aprender, de fato, a correlação entre as características, apresentando um desempenho artificialmente superior (sobreajuste, seção 1.10.2). Para evitar essas situações, existem várias técnicas aprimoradas de divisão e validação do modelo, que serão detalhadas na seção 1.8.

1.4 Tipos de Aprendizado de Máquina

O aprendizado de máquina (AM) se refere a um conjunto de métodos computacionais que possuem a capacidade de detectar padrões nos dados de forma autônoma e então usar esses padrões descobertos para prever resultados futuros (Murphy, 2012). Os dados que são utilizados por essa técnica podem se originar na forma de conjuntos de treinamento rotulados por humanos ou informações coletadas por meio do contato com o ambiente, como sensores, por exemplo. Independentemente da forma de procedência desses dados, o volume e a qualidade das informações dispostas são fundamentais para o sucesso das previsões. O AM tem diversas aplicações na Engenharia, otimizando processos e aprimorando a tomada de decisão, entre as quais, podemos citar:

- Engenharia Civil, Estrutural e de Materiais: monitoramento da saúde estrutural (SHM) (Finotti; Cury; Barbosa, 2019); predição e simulação de propriedades de materiais (Carvalho et al., 2025); otimização de seleção de materiais (Cruz et al., 2024), otimização de cronogramas de obras; estimativa da vida útil de estruturas; classificações de risco (Datta et al., 2024).
- Engenharia Elétrica e Eletrônica: detecção e previsão de falhas em redes elétricas (Samanta et al., 2025); otimização de sistemas de distribuição de energia (Hosseini; Parvania, 2021); gerenciamento inteligente de redes

(*smart grids*) (Judge et al., 2024); previsão de geração, carga e demanda energética (Lu et al., 2025); análise e correção de distúrbios na qualidade da energia (Samanta et al., 2025).

- Engenharia Mecânica e Aeroespacial: predição e otimização da manutenção preditiva de máquinas e motores; otimização aerodinâmica de aeronaves e veículos; controle autônomo de robôs industriais (Puttegowda; Nagaraju, 2025).
- Engenharia de Produção: manutenção preditiva e otimização da produção (Scaife, 2024; Arif et al., 2025); controle de qualidade automatizado (Li et al., 2024a); previsão de demanda e otimização de estoques (Sharma et al., 2021; Anukiruthika; Jayas, 2025); planejamento logístico e roteirização inteligente; balanceamento de linhas de produção (Liu et al., 2024b); precificação dinâmica (Bae; Kulcsár; Gros, 2024); análise de eficiência operacional e redução de desperdícios (Anbarasu et al., 2023; Brunello et al., 2025).
- Engenharia Ambiental: previsão e monitoramento da qualidade (Bertrand et al., 2023) do ar e da água (Jayaraman et al., 2024); detecção de vazamentos e contaminações em tempo real (Fu et al., 2022); otimização do tratamento de resíduos e efluentes (Aparna; Swarnalatha; Murchaba, 2024); modelagem de mudanças climáticas e eventos extremos (Eyring et al., 2024); análise de impacto ambiental de projetos (Du; Salasakar. Thakur, 2024); monitoramento de biodiversidade e conservação ambiental (Jansen et al., 2024); previsão de desmatamento e degradação do solo (Bag et al., 2022); otimização do uso de recursos hídricos (Ahmed et al., 2024) e energéticos (Ibrar et al., 2022).
- Engenharia Química: otimização de processos industriais (Li et al., 2021) e reatores químicos (Chowdhury et al., 2022); controle avançado de processos e automação (Liu; Hein, 2023); predição de propriedades físico-químicas de materiais e compostos (Obrezanova, 2023); modelagem e simulação de reações químicas (Venkatasubramanian; Mann, 2022).

De acordo com o tipo de aprendizado, os modelos de AM são classificados em quatro principais categorias: aprendizado supervisionado, não-supervisionado, semi-supervisionado e por reforço.


1.4.1 **Aprendizado Supervisionado**

O aprendizado supervisionado utiliza uma função de mapeamento derivada de um conjunto de dados de entrada e saída previamente rotulados, ou seja, as classes ou tipos das saídas já são conhecidos (Murphy, 2012). Por meio desse processo, o algoritmo desenvolve uma regra geral que permite mapear novas entradas para as saídas anteriormente aprendidas. Os exemplos mencionados anteriormente, das

características das flores de Íris (Tabela 1) e da predição da resistência do concreto com base em quantitativos conhecidos (de cimento, água e agregados) são tipos de aprendizado supervisionado, pois as características de entrada e saída já estão identificadas pelo(a) criador(a) do banco de dados.

Para ilustrar, a Figura 4 apresenta dois tipos de formas com características distintas: elementos angulosos e elementos curvilíneos. O algoritmo analisa parâmetros como o formato da representação, altura, largura, presença de traços ondulados ou angulosos, cores e seus tons, entre outros. Essas características representam as variáveis de entrada. Com base nesses dados, o algoritmo classifica as instâncias, limitando-se às duas saídas possíveis: elementos angulosos e elementos curvilíneos. Essa abordagem é considerada supervisionada, pois as saídas do sistema já são previamente conhecidas.

Figura 4 - Aprendizado supervisionado extrai informações e detecta padrões, nesse caso entre 2 categorias: elementos angulosos e curvilíneos



Fonte: Autores.

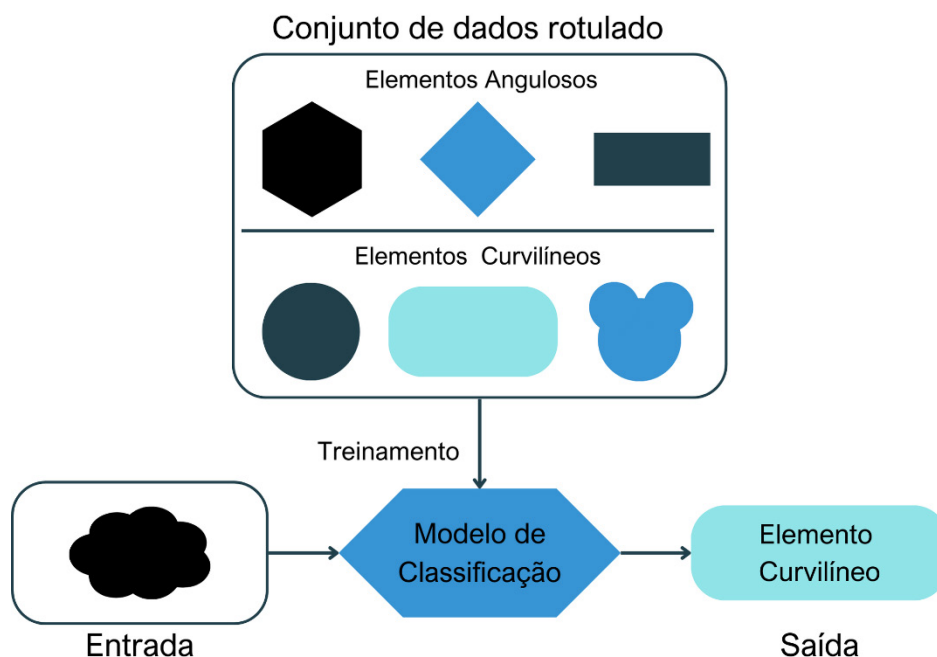
Os algoritmos de aprendizado supervisionado dependem de intervenção externa para funcionar. Durante o treinamento, os modelos são ensinados a partir de instâncias em que as variáveis de entrada e as respectivas variáveis de saída já estão identificadas. O modelo aprende a reconhecer padrões entre as variáveis de entrada, ou seja, suas características, e sua relação com as variáveis de saída. Os conjuntos de validação e teste, por sua vez, também possuem as variáveis de saída identificadas. São exemplos de algoritmos de aprendizado supervisionado mais comuns: Máquinas de Vetores Suportes (SVM), Árvores de Decisão, Floresta Aleatória, k-Vizinhos Mais Próximos (KNN), *Gradient Boosting Machines* (GBM), *Extreme Gradient Boosting* (XGBoost), LightGBM, CatBoost e Redes Neurais Artificiais (ANN).

No aprendizado supervisionado, os modelos são classificados principalmente em regressão, classificação e aprendizado de *Rank* (*Learning to Rank*). Os modelos de regressão são utilizados quando a variável de saída é contínua, ou seja, o objetivo é prever valores numéricos com base em dados de entrada (ex. valor da resistência à compressão de concretos). Já os modelos de classificação são empregados quando a variável de saída é discreta (categórica), atribuindo rótulos a novas observações (ex. classificação de uma estrutura ou equipamento em “operação normal”, “desgaste” ou “falha iminente”). Além dessas abordagens, há o aprendizado de *Rank* (*Learning to Rank*), menos comum em aplicações de engenharia, que não busca prever valores exatos ou classificar dados em categorias, mas sim ordenar itens com base em relevância ou preferência, sendo amplamente aplicado em sistemas de recomendação e mecanismos de busca, como a Netflix e o Google.

1.4.1.1 Classificação

O objetivo da classificação no aprendizado supervisionado é atribuir cada entrada a uma categoria específica. Nesse processo, as entradas são organizadas em duas ou mais classes, e o modelo deve associar corretamente novas instâncias a uma ou mais dessas categorias (Mahesh, 2018). Com base nos treinamentos realizados com dados rotulados e categorias conhecidas, o algoritmo de classificação aprende a prever a categoria de novas instâncias a partir dos padrões observados nos dados anteriores. Esse processo é ilustrado na Figura 5.

Figura 5 - Exemplo de classificação no aprendizado de máquina



Fonte: Autores.


1.4.1.2 Regressão

Nos problemas de regressão, as saídas são valores contínuos em vez de categorias discretas, sendo utilizados para prever valores reais para cada instância (Flach, 2022).

A penalidade por uma predição incorreta em regressão é determinada pela diferença absoluta entre o valor real e o valor predito, ao contrário dos problemas de classificação, onde geralmente não há noção de proximidade entre as categorias (Mohri, Rostamizadeh, Talwalkar, 2018).

Os modelos de regressão utilizam métodos estatísticos para estimar a relação entre a variável de saída e as variáveis independentes que a influenciam, denominadas parâmetros de influência (Yildiz, Bilbao Sproul, 2017).

A Figura 6 apresenta um exemplo de curva de regressão, onde os dados do banco de dados são representados pelos pontos no gráfico. A linha azul da figura ilustra a curva de regressão, que gera uma equação para estimar valores de saída com base em novas entradas.



Fonte: Autores.

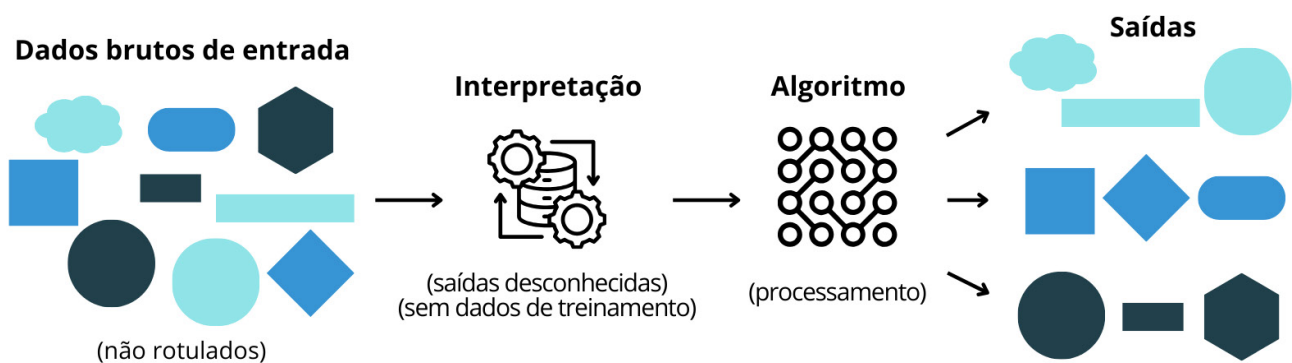
Problemas de regressão em que as variáveis de entrada estão organizadas cronologicamente são classificados como problemas de previsão de séries temporais, enquanto aqueles que envolvem múltiplas variáveis de entrada são conhecidos como problemas de regressão multivariada. Como os resultados de regressão nem sempre são exatos, é essencial avaliar a precisão dos modelos por meio de métricas como o coeficiente de determinação (R^2), o erro absoluto médio (MAE) e o erro quadrático médio (RMSE), que serão detalhadas na seção 1.9.

1.4.2 Aprendizado Não Supervisionado

O aprendizado não supervisionado utiliza dados não rotulados com o objetivo de identificar semelhanças e diferenças entre as instâncias analisadas, agrupando-

as conforme essas características (Batista, 2023; Souza et al., 2020). Nesse contexto, os algoritmos operam de forma independente, buscando revelar uma estrutura de dados que seja relevante para o(a) usuário(a). Esses algoritmos aprendem recursos específicos dos dados e, ao serem introduzidas novas informações, utilizam o conhecimento adquirido previamente para reconhecer e caracterizar os novos dados (Mahesh, 2018). A Figura 7 apresenta o fluxo de trabalho associado aos algoritmos de aprendizado não supervisionado. Esse tipo de aprendizado abrange a solução de problemas relacionados a agrupamento, generalização e associação (Mohd, Masrom Johari, 2019).

Figura 7 - Fluxo de trabalho no aprendizado não-supervisionado



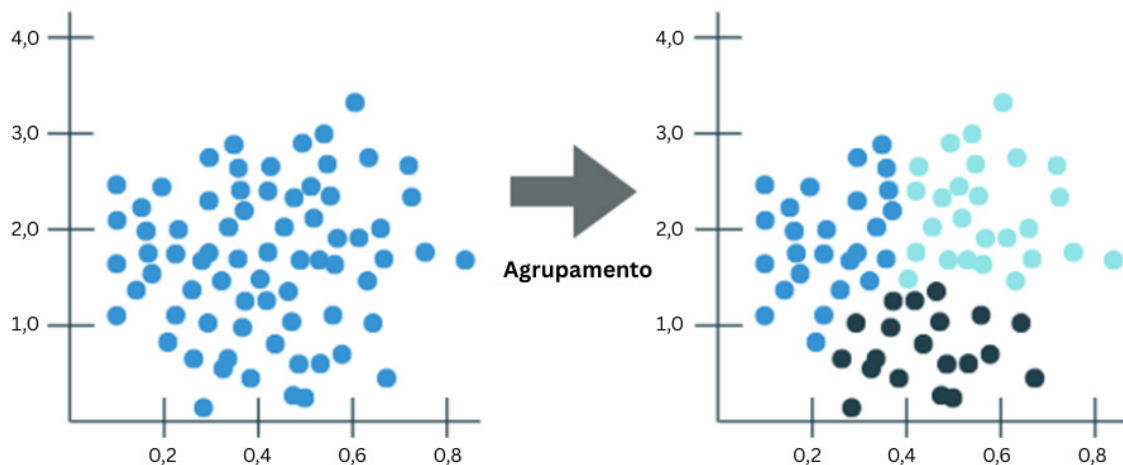
Fonte: Autores.

1.4.2.1 Agrupamento

No campo da ciência de dados e IA, informações isoladas geralmente são insuficientes para análise; o significado emerge do conjunto formado, ou seja, do agrupamento. O agrupamento (*clustering*), também denominado clusterização, é uma técnica de classificação não supervisionada que organiza itens em classes comparáveis, segmentando os dados em subgrupos com base em semelhanças identificadas (Jain; Murty; Flynn, 1999; Huang et al., 2020). Objetos (ou observações ou instâncias) semelhantes em determinados aspectos são atribuídos ao mesmo grupo, enquanto objetos distintos pertencem a grupos separados. Esse processo desempenha um papel fundamental na organização e análise de grandes volumes de dados, permitindo que padrões ocultos sejam identificados e utilizados para otimização e tomada de decisão em diversas áreas.

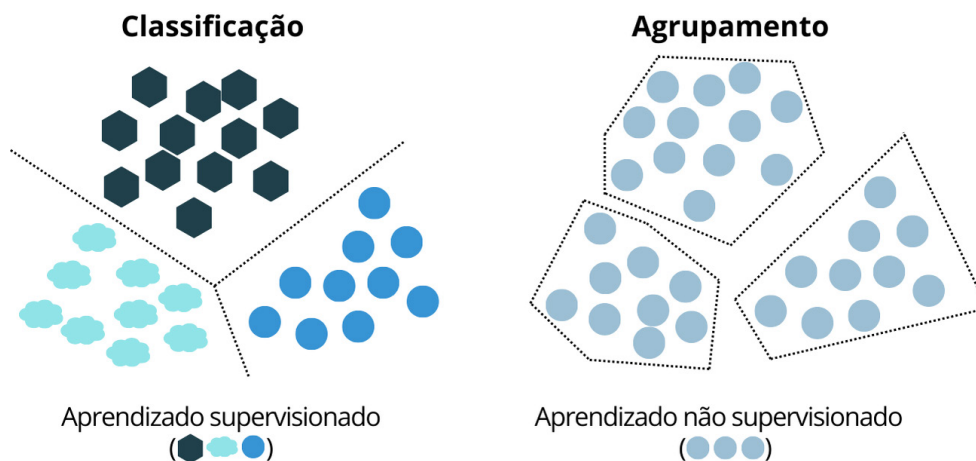
Um exemplo de agrupamento é ilustrado na Figura 8. No gráfico à esquerda, os dados originais estão plotados sem segmentação. Após a aplicação do algoritmo de agrupamento, como mostrado no gráfico à direita, os dados semelhantes são diferenciados por colorações distintas, formando subgrupos. A diferença do agrupamento, que é um tipo de aprendizado não-supervisionado, para a classificação, que é do tipo supervisionado (seção 1.4.1.1), é que no primeiro não há rotulagem dos dados (Figura 9).

Figura 8 - Exemplo de agrupamento (clusterização)



Fonte: Autores.

Figura 9 – Diferença entre classificação (tipo de aprendizado supervisionado, rotulado) para agrupamento (não supervisionado)



Fonte: Autores.

Existem diversas técnicas de agrupamento, adotadas conforme o tipo de problema:

- a) **Agrupamento Aglomerativo**: começa com cada objeto sendo um agrupamento separado e, gradativamente, agrupa os mais próximos até formar um número menor de agrupamentos; ou **Agrupamento Divisivo**: que começa com um único agrupamento e o divide em subconjuntos menores até satisfazer o critério de parada. Essas classes são usadas principalmente em métodos hierárquicos, úteis para análise exploratória e visualização da estrutura dos dados.
- b) **Agrupamento Politético**: utiliza todos os atributos disponíveis para calcular distâncias entre os objetos, enquanto o **Agrupamento Monotético** baseia-

se em um único critério ou atributo a cada etapa para divisão dos objetos. São geralmente utilizados em aplicações práticas de Engenharia.

- c) **Agrupamento Rígido:** aloca os objetos em um único agrupamento, sem sobreposição, enquanto o **Agrupamento Difuso** (ou *Fuzzy*) permite que um objeto pertença a múltiplos agrupamentos, atribuindo graus de pertinência. O agrupamento rígido é adotado quando o problema exige apenas um agrupamento por objeto, enquanto o difuso é útil quando os *clusters* podem ter sobreposição, como no processamento de imagens.

O tipo de algoritmo adotado pode ser determinístico ou estocástico, dependendo da abordagem para otimização de erro quadrado. Da mesma forma, a escolha entre algoritmos incrementais ou não incrementais depende do volume de dados e das restrições de tempo e memória (Jain; Murty; Flynn, 1999). A depender da abordagem utilizada para segmentar os dados, os algoritmos de agrupamento classificam-se principalmente em (Halkidi; Batistakis; Vazirgiannis, 2001):

- a) **Particionamento:** divide os dados de um conjunto em agrupamentos distintos, otimizando iterativamente uma função matemática de critério, geralmente minimizando a distância *intra-cluster*. O *k-means* é um dos algoritmos mais populares de aglomeração e pertence a essa metodologia.
- b) **Hierárquico:** cria uma estrutura hierárquica de agrupamentos, uma árvore de correlação ou dendrograma, que representa as relações entre os agrupamentos formados por aglomeração ou divisão.
- c) **Baseado em Densidade:** forma agrupamentos considerando a densidade dos pontos em uma região.
- d) **Baseado em Grade (Engradamento):** divide o espaço dos dados em células de grade e agrupam os pontos com base na densidade dessas células.

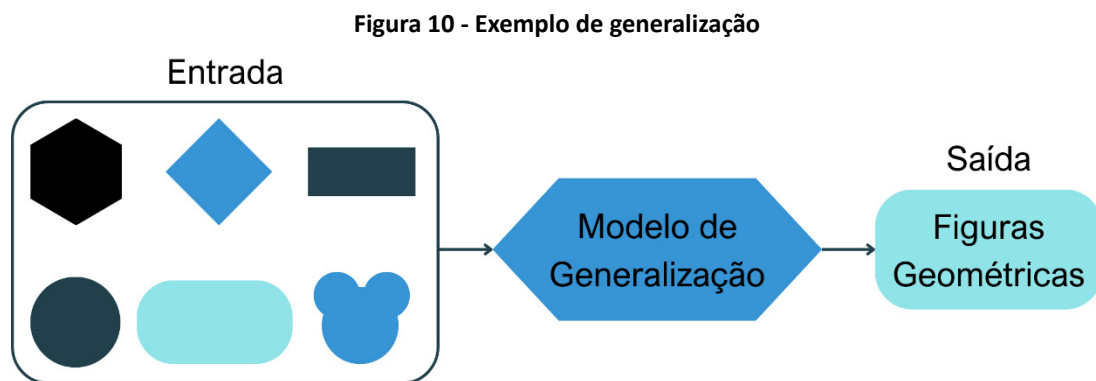
Outras estratégias: modelos probabilísticos, que utilizam distribuições estatísticas para modelar os dados e definir *clusters* com base na probabilidade de pertencimento; e Grafos e Redes, que modelam os dados como um grafo, onde os pontos são nós conectados por arestas, permitindo identificar *clusters* com base na estrutura das conexões.

Após o processo de agrupamento, sua validação é fundamental para garantir que os grupos formados sejam coerentes, significativos e úteis para a análise de dados. Como o aprendizado não supervisionado não possui rótulos predefinidos, a validação do agrupamento se torna mais complexa. Existem três principais abordagens para avaliar a qualidade dos *clusters*: métricas internas, que avaliam a qualidade do

agrupamento com base apenas nos próprios dados e nas relações entre os pontos dentro dos agrupamentos; métricas externas, que são usadas quando há um conjunto de rótulos disponíveis para comparar os agrupamentos gerados com a classificação real dos dados; e a validação baseada em estabilidade, que testa a estabilidade dos agrupamentos sob diferentes condições e perturbações.

1.4.2.2 Generalização

A generalização busca identificar características detalhadas nos dados, detectando padrões não convencionais que permitam a criação de novas informações ou padrões generalizados (Grando, 2022). A Figura 10 mostra um exemplo: a partir de conjunto diverso de figuras, o algoritmo generaliza o conjunto como representando “figuras geométricas”. Essa técnica é amplamente utilizada em jogos para sugerir ações ou caminhos a seguir, assim como em *sites* de varejo e aplicativos de trânsito.



Fonte: Autores.


Como um outro exemplo, em um almoxarifado, diversas chaves de fenda possuem tamanhos, cores e finalidades diferentes. O algoritmo pode identificar todas as chaves com ponta retangular e classificá-las como adequadas para manutenção de bicicletas. Esse padrão é criado a partir da observação de um comportamento recorrente nos dados. Na Engenharia, esse tipo de AM pode agrupar diferentes elementos conforme suas características (ex. edificações, mapas de poluição) e reconhecer padrões em séries temporais (ex.: consumo de energia, categorização de comportamento normal ou anômalo de sistemas).

1.4.2.3 Associação

Os problemas de associação envolvem a identificação de padrões em dados dispostos em sequência, sem a necessidade de rótulos. Após identificar o padrão, o algoritmo é capaz de prever como completar a sequência. Essa abordagem é amplamente utilizada para descobrir relações ocultas entre elementos dentro de um conjunto de dados, permitindo prever associações futuras ou otimizar processos. A Figura 11 exemplifica o processo: em uma sequência composta por elementos

angulosos intercalados com elementos curvilíneos, o algoritmo analisa os dados e sugere “elemento curvilíneo preto” como a próxima informação mais provável.

Figura 11 - Exemplo de associação



Fonte: Autores.

O exemplo mais comum do uso desse mecanismo é em *sites* de vendas, para prever compras adicionais com base nos itens escolhidos anteriormente pelo usuário. Por exemplo, ao adquirir um celular e um carregador, o algoritmo pode sugerir ao(à) usuário(a) um fone de ouvido ou uma capa protetora. Na Engenharia, as regras de associação podem ser usadas para identificar relações entre materiais e falhas estruturais; identificar padrões de falha em sensores, relacionando variações de temperatura, vibração e pressão com futuras falhas mecânicas; detectar quais processos ou máquinas tendem a apresentar certos comportamentos juntos; identificar associações entre condições meteorológicas e níveis de poluentes; descobrir relações entre componentes químicos e propriedades desejadas em materiais, entre outros.

1.4.3 Outros tipos de aprendizado de máquina

Menos comumente adotados em problemas clássicos de Engenharia, o aprendizado semi-supervisionado combina elementos do aprendizado supervisionado e do não supervisionado, utilizando certos conjuntos de dados rotulados (geralmente uma minoria) e um grande volume de dados não rotulados. Assim, o modelo aprende a estruturar os dados e a aprender padrões; economizando tempo do(a) desenvolvedor(a) na rotulagem, sem perder muita acurácia. Esses tipos de modelos são geralmente aplicados a problemas que envolvem um grande volume de dados nos quais a rotulagem demanda grandes esforços, como a detecção de doenças a partir de exames médicos, nos quais apenas um subconjunto das imagens foi rotulado por especialistas; para a predição de propriedades físicas de novos materiais com base em um pequeno conjunto de amostras já testadas e para a previsão de comportamentos (ex. consumo de energia, dispersão de poluição), embora só uma parte dos dados históricos tenha sido correlacionada.

Por fim, o aprendizado por reforço (*Reinforcement Learning*) é um método baseado em interação com o ambiente, no qual um agente aprende por tentativa e erro, recebendo recompensas ou penalidades conforme suas ações. Esse

método independe de rótulos ou instruções atribuídos por humanos. Embora essa característica também seja definidora do aprendizado não-supervisionado, no aprendizado por reforço, o agente toma decisões sequenciais e avalia o impacto de suas ações no ambiente, buscando maximizar recompensas ao longo do tempo; ele não busca encontrar padrões ocultos nos dados.

Esse tipo de modelo é muito usado para problemas complexos de otimização e controle; como otimização de rotas e alocação de recursos; controle de robôs e carros autônomos e braços mecânicos; gerenciamento automático de redes elétricas inteligentes (*smart grids*), entre outros. São exemplos de algoritmos comuns no aprendizado por reforço: Aprendizado Q (*Q-Learning*), *Deep Q-Networks (DQN)*, Otimização de Política Proximal (*Proximal Policy Optimization - PPO*) e Métodos de Monte Carlo.

1.5 Pré-Processamento de Dados

Os dados brutos coletados no mundo real frequentemente apresentam imprecisões, incompletudes ou incorreções, sendo caracterizados por diversas anomalias ocasionadas por diferentes fatores, que serão discutidos ao longo desta seção. Assim, um banco de dados pode conter informações irrelevantes ou até prejudiciais ao modelo, tornando necessária uma preparação inicial. Nesse contexto, o pré-processamento de dados assume um papel relevante devido à sua influência direta na precisão dos algoritmos de AM, uma vez que dados de entrada de baixa qualidade comprometem o desempenho dos modelos (Alexandropoulos; Kotsiantis; Vrahatis, 2019). Além disso, destaca-se que a entrada deve ser fornecida em um formato apropriado e eficiente para o método de AM selecionado. Nesse cenário, a representação e a qualidade de um conjunto de dados são propriedades fundamentais.

O pré-processamento se divide em quatro etapas principais: limpeza de dados; integração de dados; transformação de dados; e, por último, redução. A limpeza de dados consiste em uma fase essencial que aborda estratégias para tratar problemas relacionados a dados ausentes, ruidosos e inconsistentes. A segunda etapa é a integração de dados, focada na consolidação de múltiplas fontes heterogêneas em um único banco de dados coerente. A terceira etapa refere-se à transformação de dados brutos, que inclui mudanças de escala ou de formato para adequação às necessidades do modelo, analisando aspectos como normalização e discretização. Por fim, a última etapa é a redução de dados, voltada para a eliminação de informações redundantes ou irrelevantes, visando à eficiência no armazenamento e à melhoria do desempenho dos métodos de AM.

1.5.1 *Limpeza de Dados*

A etapa de limpeza de dados visa abordar as principais anomalias que surgem frequentemente em grandes bases de dados: dados faltantes, dados ruidosos e dados inconsistentes.

1.5.1.1 *Dados Faltantes*

A ausência de dados é um problema comum em situações reais. Dados faltantes podem resultar de falhas durante a aquisição, erros humanos, problemas de armazenamento ou omissões nas bases de dados.

A solução mais simples é a exclusão de registros com valores ausentes. No entanto, quando o volume de dados faltantes é elevado, essa abordagem pode levar à perda significativa de informações. Além disso, a exclusão pode introduzir viés nos resultados, principalmente se a ausência de dados não for aleatória. Por exemplo, a remoção de uma classe com maior propensão a valores faltantes pode desbalancear os dados, afetando negativamente o modelo (Batista, 2003).

Outras abordagens para tratar valores ausentes incluem preenchimento manual, o que é inadequado para grandes conjuntos de dados devido ao tempo necessário, ou o uso de valores constantes, como substituir valores ausentes por zero. Essa técnica, embora prática, pode gerar inferências problemáticas se os dados forem interpretados de forma incorreta pelos algoritmos (Alasadi; Bhaya, 2017).

Métodos estatísticos, como o uso da média ou mediana de um atributo, são alternativas mais comuns. A sofisticação aumenta quando os valores são calculados com base em grupos similares, como medições de estações meteorológicas próximas para estimar dados faltantes em uma estação central. Técnicas probabilísticas, como a máxima verossimilhança, e métodos baseados em aprendizado de máquina, como K-vizinhos mais próximos (KNN), redes neurais artificiais (ANN) e máquinas de vetor suporte (SVM), também são amplamente utilizados (Garcia; Luengo; Herrera, 2015).

1.5.1.2 *Dados Ruidosos*

Dados ruidosos incluem erros ou desvios indesejados que afetam a relevância estatística de um modelo (Prakash; Navya; Natarajan, 2018). A presença de ruído nos dados reduz a eficiência de algoritmos de AM, tornando a sua redução ou remoção essencial. O ruído pode ser classificado em dois tipos principais: ruído de classe, associado a rótulos incorretos, e ruído de atributo, causado por erros nos valores das amostras (Zhu; Wu, 2004). O ruído de classe ocorre quando as amostras são rotuladas incorretamente e são geralmente mais fáceis de tratar (Sáez; Corchado, 2022). O ruído de atributo é reproduzido por erros numéricos nas amostras. Esse último tipo de erro é observado no exemplo de aplicação apresentado na Tabela 2, no qual os dados estão fora do intervalo usual esperado: os atributos “Nota” e “Idade” assumindo

valores negativos, por exemplo. Algumas das maneiras mais recorrentes de se lidar com ruídos no conjunto de dados são: engradamento, regressão e agrupamento.

Tabela 2 – Exemplo de ruído de atributo

Matrícula	Nome	Idade	Nota (0 a 10)	Situação
2022001	Ana	22	10	Aprovado
2022002	Beto	-5	3	Reprovado
2022003	Clara	23	7	Aprovado
2022004	Daniel	21	11	Aprovado
2022005	Elisa	300	2	Reprovado
2022006	Fábio	3,2	7	Aprovado
2022007	Gabriel	22	-1	Reprovado

Fonte: Autores.

Técnicas como o engradamento, que suaviza dados ao substituir valores por médias ou medianas em intervalos específicos (caixas), são úteis para lidar com variações pequenas. Alternativamente, a regressão pode ajustar curvas para suavizar dados, enquanto métodos de agrupamento destacam os sobreajustes ao identificar valores fora de grupos homogêneos.

Em algumas situações, ruídos podem ser intencionalmente adicionados, como em simulações que visam avaliar a robustez de algoritmos em ambientes controlados. Ruídos artificiais, como os de distribuição gaussiana ou uniforme, são amplamente utilizados em áreas como processamento de imagens e sinais, permitindo testes sob diferentes níveis de interferência.

1.5.1.3 Dados Inconsistentes

Inconsistências podem ocorrer em bases de dados devido a diferentes fatores. Algumas situações são corrigíveis manualmente, com base em referências externas. Nesse contexto, é relevante o conhecimento sobre a área de estudo, pois ele permite identificar violações em restrições conhecidas.

Outra forma de inconsistência surge quando há alterações no padrão lógico ou no formato de representação de um atributo. Por exemplo, na Tabela 3, o atributo “Nota” apresenta a categoria “A”, enquanto os demais valores são numéricos. Embora “A” não seja ruidoso, é considerado inconsistente, já que corresponde a uma mudança no padrão de representação. O mesmo ocorre em “MMXXII003”, no qual o valor decimal “2022” foi substituído pela notação romana “MMXXII”, seguida do identificador “003”. Por fim, a atribuição de “reprovado” a uma nota 7, como se vê no caso do aluno Fábio, também é uma inconsistência, dado que a nota mínima de aprovação neste caso é 6.

Tabela 3 - Exemplo de dados Inconsistentes

Matrícula	Nome	Idade	Nota (0 a 10)	Situação
2022001	Ana	22	10	Aprovado
2022002	Beto	21	F	Reprovado
MMXXII003	Clara	23	7	Aprovado
2022004	Daniel	21	6	Aprovado
2022005	Elisa	23	2	Reprovado
2022006	Fábio	21	7	Reprovado
2022007	Gabriel	22	A	Aprovado

Fonte: Autores.

1.5.2 Integração de Dados

Após a limpeza dos dados, a sua integração consiste na fusão de múltiplas fontes heterogêneas (e.g.: bancos de dados, arquivos simples) em um conjunto coerente. Esse processo enfrenta desafios como identificar relações entre bases e eliminar duplicatas. Além disso, diferenças de padronização entre fontes são comuns. Por exemplo, uma base pode representar a localização como “Minas Gerais”, enquanto outra utiliza “MG”. Nesse caso, a integração unifica as representações para análise.

Como exemplo, Pita (2023) montou um banco de dados coletando informações sobre 306 imóveis vendidos na cidade de Juiz de Fora - MG, no período de 2016 a 2023. Os dados eram provenientes de três empresas imobiliárias e de um agente corretor de imóveis. O autor destaca que a coleta de dados “se apresentou como uma tarefa árdua”, pois a grande maioria das fontes não possuía as informações sobre os imóveis vendidos de forma estruturada, nem registrava as mesmas características para os imóveis (ex.: nem todas registravam o padrão de acabamento ou se a vaga de garagem era livre ou presa). Adicionalmente, os endereços eram registrados de formas diferentes (ex.: incluindo ou não o CEP e a região da cidade). Dessa forma, a equipe precisou realizar uma morosa integração dos dados, mantendo as informações comuns a todas as instâncias e compatibilizando a forma de apresentação.

Adicionalmente, alguns dados ou categorias podem ser redundantes, o que vai além de duplicações. Um atributo é considerado redundante se pode ser derivado de um subconjunto de outros atributos, não adicionando informações novas nem contribuindo para o aprendizado dos métodos de IA. Análises de correlação são frequentemente usadas para detectar redundâncias.

1.5.3 Transformação de Dados

A qualidade dos dados é essencial para o desempenho de algoritmos de aprendizado. Bases de dados frequentemente contêm atributos em formatos

inadequados para mineração, necessitando transformação. Esse processo gera novos atributos em formatos apropriados, eliminando erros que poderiam comprometer a precisão dos modelos. As principais técnicas incluem normalização e discretização.

1.5.3.1 Normalização

A normalização ajusta a escala ou a distribuição dos dados para garantir que todos os atributos tenham influência equivalente na predição (Singh; Singh, 2020). Contudo, isso não implica igual importância entre os atributos, já que alguns podem ser irrelevantes ou redundantes. Técnicas de mudança de escala geralmente ajustam os dados para intervalos como $[0,1]$ ou $[-1,1]$, reduzindo o viés de atributos com valores numericamente maiores e equilibrando sua influência no modelo.

Como exemplo, Paixão et al. (2022) reportaram terem feito uma normalização dos dados dos componentes do concreto para a faixa $[-1,1]$ para aprimorar o resultado do modelo de Redes Neurais Artificiais. O conjunto de dados original possuía valores de consumo de agregado graúdo variando entre 656,3 e 1.029,0 kg/m^3 , enquanto o consumo de superplastificante variava apenas entre 0,0 e 11,3 kg/m^3 . Essa diferença na ordem de grandeza fazia com que a técnica atribuísse maior importância para a categoria de agregado graúdo, o que não é o caso. Técnicas que adotam estruturas de árvores, como o XGBoost, geralmente não são influenciadas por essa diferença de escala.

A normalização Min-Max converte a escala de um atributo x em $x_{Min-Max}$, usando os valores mínimo e máximo de x , conforme mostra a Equação 1:

$$x_{MinMax} = a + \left[\frac{x - \min(x)}{\max(x) - \min(x)} \right] (b - a) \quad \text{Equação 1}$$

Note-se que a equação foi generalizada para um intervalo arbitrário $[a,b]$. Porém, a técnica de Min-Max pode se tornar ineficaz na presença de valores atípicos ou quando os valores extremos de x não são plenamente conhecidos. Assim, outra estratégia de normalização útil, também chamada de Padronização, ou *z-score*, que foca em alterar a distribuição dos dados. Ao usar essa transformação, o atributo passa a ter média igual a zero e desvio-padrão unitário. A normalização *z-score* é obtida a partir da Equação 2,

$$z = \frac{x - \underline{x}}{\sigma_x} \quad \text{Equação 2}$$

onde \underline{x} e σ_x são a média e o desvio-padrão do atributo em questão, respectivamente.

1.5.3.2 Discretização

Algoritmos de aprendizado de máquina frequentemente operam com dados de entrada não contínuos (García et al., 2016), como ocorre em alguns métodos baseados em árvores de decisão. Mesmo algoritmos sem essa restrição podem apresentar redução na eficiência de aprendizagem quando o número de atributos é elevado (Cios et al., 2007). No entanto, dados do mundo real são comumente coletados em formatos contínuos, demandando técnicas como a discretização (*binning*) para converter atributos contínuos em discretos ou categóricos. Esse processo permite transformar dados quantitativos em qualitativos, como exemplificado na Tabela 4, que categoriza o atributo “Idade” em quatro faixas. A discretização facilita a gestão e interpretação dos dados, reduzindo sua complexidade e tempo de processamento, além de melhorar a precisão dos modelos. Contudo, uma limitação importante dessa abordagem é a potencial perda de informações.

Tabela 4 - Aplicação de discretização de faixa etária

Atributo	Idade	Idade	Idade	Idade
Intervalo (anos)	[0,11]	[12,17]	[18,65]	>65
Categoria	Criança	Adolescente	Adulto	Idoso

Fonte: Autores.

A discretização uniforme divide os dados em intervalos de mesmo tamanho. A discretização baseada em frequência distribui os dados de modo que cada grupo contenha o mesmo número de observações. Algumas distribuições mais avançadas, envolvendo algoritmos (ex.: *Decision Tree Binning*) podem ser adotadas para encontrar limites ótimos automaticamente. Entre as metodologias mais empregadas para discretização, destacam-se a análise de histogramas, o método de engradamento e a análise de agrupamento.

Adicionalmente, o processo inverso pode ser necessário, convertendo atributos categóricos ordenados em valores numéricos proporcionais à ordem estabelecida. Um exemplo é a modelagem de risco de crédito, onde “baixo risco” é representado por 1, “médio risco” por 2 e “alto risco” por 3. Essa conversão, também chamada codificação (*encoding*), será tratada na seção 1.6.

1.5.4 Redução de Dados

Na era do *Big Data*, o volume de dados eleva significativamente os custos computacionais relacionados ao seu armazenamento, processamento e análise. Nesse contexto, o processo de redução de dados busca minimizar a dimensão e os custos computacionais do conjunto, ao mesmo tempo em que aumenta a eficiência no armazenamento e no treinamento de modelos de IA. Entre as estratégias para redução de dados, assumindo que já foi feita a limpeza dos dados, pode-se citar:

- **Redução da dimensionalidade:** redução no número de características/variáveis. Essa estratégia será detalhada na seção 1.7;
- **Amostragem de Dados (Data Sampling):** nessa abordagem, ao invés de se usar todo o conjunto de dados para treinar, testar e validar o modelo, seleciona-se uma amostra representativa, reduzindo o volume de dados processados sem perder a qualidade da informação. Essa amostragem por ser aleatória simples, estratificada (mantendo-se a proporção de diferentes classes); por *cluster* (usando estratégias de agrupamento/ clusterização); ou por *bootstrapping* (que cria várias amostras menores para simulações e validações estatísticas).
- **Agregação e Resumo de Dados:** nesse caso, as instâncias são agregadas em grupos representativos ou convertidas em valores estatísticos que as representam. Isso pode ser feito por médias, medianas, agrupamento temporal (no caso de séries temporais, como agrupando valores diários por semana ou mês) e por histogramas.
- **Compactação de Dados (Data Compression):** busca reduzir o tamanho dos dados armazenados sem perder informações essenciais, como compactar imagens em JPEG ou músicas em MP3.

1.6 Variáveis Numéricas e Categóricas

As características ou variáveis de entrada e saída, em modelos de AM e AP, podem ser classificadas em dois tipos: numéricas e categóricas. As variáveis numéricas são aquelas que representam quantidades mensuráveis. Elas podem assumir valores em uma escala contínua (ex.: temperatura, resistência à compressão, valor de corrente) ou discreta (ex.: número de pavimentos, quantidade de sensores, número de pessoas), permitindo operações matemáticas.

Variáveis categóricas representam classes, categorias, rótulos ou grupos, em vez de valores numéricos contínuos (Hair et al., 2013). Elas são geralmente usadas para expressar atributos qualitativos. As variáveis categóricas podem ser divididas em duas principais categorias: nominais e ordinais. As nominais não têm uma ordem intrínseca (ex.: cores, nacionalidade, sexo), enquanto as ordinais têm uma ordem natural (ex.: nível de escolaridade, nível de satisfação) (Agresti, 2018).

Como exemplo, na Figura 12, as variáveis numéricas (ex.: a proporção de cimento, areia, brita e água) representam valores quantitativos e podem ser medidas em uma escala contínua. As classificações em forma de palavra dos tipos de compósitos (“concreto”, “argamassa” e “pasta de cimento”) são variáveis categóricas nominais, pois não possuem hierarquia.

Figura 12 – Exemplo de categorias na classificação de tipos de compósitos cimentícios

Traço	Cimento	Areia	Brita	Água	Tipo de compósito
001	1	2,2	3,0	0,35	Concreto
002	1	2,5	2,9	0,40	Concreto
003	1	3,1	NA	0,25	Argamassa
004	1	NA	NA	0,70	Pasta de Cimento
005	1	3,1	2,0	0,30	Concreto
006	1	NA	NA	0,20	Pasta de Cimento
007	1	NA	NA	0,30	Pasta de Cimento

Fonte: Autores.

O uso de variáveis categóricas em AM e AP pode apresentar desafios, pois os algoritmos geralmente requerem que os dados sejam representados numericamente. Uma possibilidade seria excluir variáveis não numéricas, embora isso possa causar perda significativa de informações. Assim, as variáveis categóricas geralmente são convertidas em valores numéricos apropriados antes de serem usadas como entrada nos modelos, por meio de uma técnica de transformação chamada codificação (*encoding*), realizada por algoritmos denominados codificadores (*encoders*).

Um desafio da codificação é a ordinalidade, pois pode existir uma ordem intrínseca entre as categorias e isso pode não ser reconhecido pelos algoritmos, afetando os resultados (ou vice-versa – os algoritmos podem perceber uma ordem de superioridade onde não há) (Bishop, 2006; Hastie, T.; Tibshirani, R.; Friedman, J., 2009; James et al., 2017) . Outro desafio é a dimensionalidade, pois quando um modelo possui muitas variáveis categóricas com muitas classes, a dimensão do conjunto de dados pode aumentar significativamente, tornando os modelos mais complexos e requerendo maior tempo de treinamento e capacidade computacional (Bishop, 2006; Hastie, T.; Tibshirani, R.; Friedman, J., 2009; James et al., 2017).

Existem diversas formas de se classificar os codificadores. Nesse livro, detalharemos os codificadores clássicos e bayesianos, mas também existem codificadores de contraste, classificadores e de frequência. Os codificadores clássicos

substituem as variáveis categóricas por valores numéricos, enquanto os codificadores bayesianos realizam essa substituição utilizando dados da variável-alvo para isso (Fontelles, 2020). Outras formas de divisão incluem em clássicos (que simplesmente substituem valores por números), *embeddings* de entidades (representações vetoriais de categorias, comumente usados quando as variáveis categóricas são representadas por vetores densos aprendidos durante o treinamento de redes neurais), *embeddings* de palavras (representações vetoriais de palavras, tipicamente usado para converter palavras em vetores numéricos que preservam o significado contextual) e híbridos.

1.6.1 Codificadores Clássicos

Os codificadores clássicos que trataremos nessa seção são os de rótulo, *one-hot* e ordinal. Existem também classificadores binários (*binary encoding*) e codificadores por função *hash* (*hash encoding* / *hashing trick*), entre outros.

1.6.1.1 Codificador de Rótulo

O codificador de rótulo (*label encoding*) consiste na substituição de variáveis categóricas por valores numéricos que as representam. Essa estratégia pode conduzir a problemas de hierarquia durante o treinamento do modelo, pois uma classe com um valor alto pode ser considerada de maior prioridade do que outra com um valor menor (Yadav, 2019). Esse problema não é enfrentado por algoritmos que não consideram as escalas dos dados.

Por exemplo, o Instituto Brasileiro de Geografia e Estatística (IBGE) utiliza códigos numéricos de 7 dígitos (ex.: 3146107, 3145901 e 3136702) para cada município (Ouro Preto, Ouro Branco e Juiz de Fora, respectivamente) (IBGE, 2025). A Figura 13 exemplifica o uso desse codificador em classificação de tipos de cimento, onde os rótulos CP I, CP I-S, CP II-Z, CP III, CP IV e CPB foram codificados como 0, 1, 2, 3, 4 e 5, respectivamente, apenas pela ordem alfabética, sem haver hierarquia implícita entre os tipos.

Figura 13 - Codificador de Rótulos

Cimento	Tipo		Cimento	Tipo
001	CP I - S	→	001	1
002	CP III		002	3
003	CP II - Z		003	2
004	CP I		004	0
005	CP IV		005	4
006	CPB		006	5
007	CP II - Z		007	2

Fonte: Autores.

1.6.1.2 Codificador One-Hot

O codificador *one-hot* (ocasionalmente referido por codificador binário por presença), por sua vez, converte uma coluna com n rótulos em n colunas, cada qual representando um rótulo (Svideloc, 2020; Terra, 2021; Möbius, 2021). Essa técnica utiliza valores binários: 0 para ausência e 1 para presença da categoria. A Figura 14 exemplifica esse processo, com uma coluna contendo três categorias (concreto, argamassa e pasta de cimento) transformada em três colunas independentes. Como vantagem, essa técnica preserva a distância entre as categorias, pois cria colunas binárias distintas para cada classe. Por outro lado, pode levar a um aumento significativo no número de variáveis e isso pode resultar em um problema de multicolinearidade, onde as colunas binárias estão altamente correlacionadas (Teles, 2023).

Figura 14 - Codificador One-Hot

Traço	Tipo de compósito		Traço	Concreto	Argamassa	Pasta de Cimento
001	Concreto	→	001	1	0	0
002	Concreto		002	1	0	0
003	Argamassa		003	0	1	0
004	Pasta de Cimento		004	0	0	1
005	Concreto		005	1	0	0
006	Pasta de Cimento		006	0	0	1
007	Pasta de Cimento		007	0	0	1

Fonte: Autores.

1.6.1.3 Codificador Ordinal e Codificador de Rótulo

O codificador ordinal se aplica a variáveis categóricas ordinais que não correspondem aos dados-alvo. Essa técnica substitui categorias por números inteiros que, por sua natureza, possuem ordenação implícita (Terra, 2021; Möbius, 2021). Esse codificador é bastante utilizado em variáveis que envolvem algum tipo de hierarquia ou progressão lógica, como em avaliações de qualidade (ruim, regular, boa, excelente), escalas de percepção (nunca, às vezes, frequentemente, sempre), classificações de risco (baixo, médio, alto) e prioridades de manutenção (urgente, importante, eventual). A Figura 15 mostra um exemplo de classificação de satisfação dos(as) usuários(as) em relação ao conforto térmico em diversas edificações.

Figura 15 - Codificador Ordinal

Edifício	Nível de satisfação		Edifício	Nível de satisfação
001	Alto		001	3
002	Baixo		002	1
003	Muito Baixo	→	003	0
004	Alto		004	3
005	Médio		005	2
006	Muito Baixo		006	0

Fonte: Autores.

1.6.2 Codificadores Bayesianos

Entre os codificadores bayesianos mais comuns, vamos detalhar o codificador de alvo (ou codificador por alvo ou codificador pela média) e o de James-Stein. Mas, também, existem o codificador alvo com suavização, a codificação por exclusão de instância (*leave-one-out encoding*) e a codificação empírica, entre outros.

1.6.2.1 Codificador de Alvos

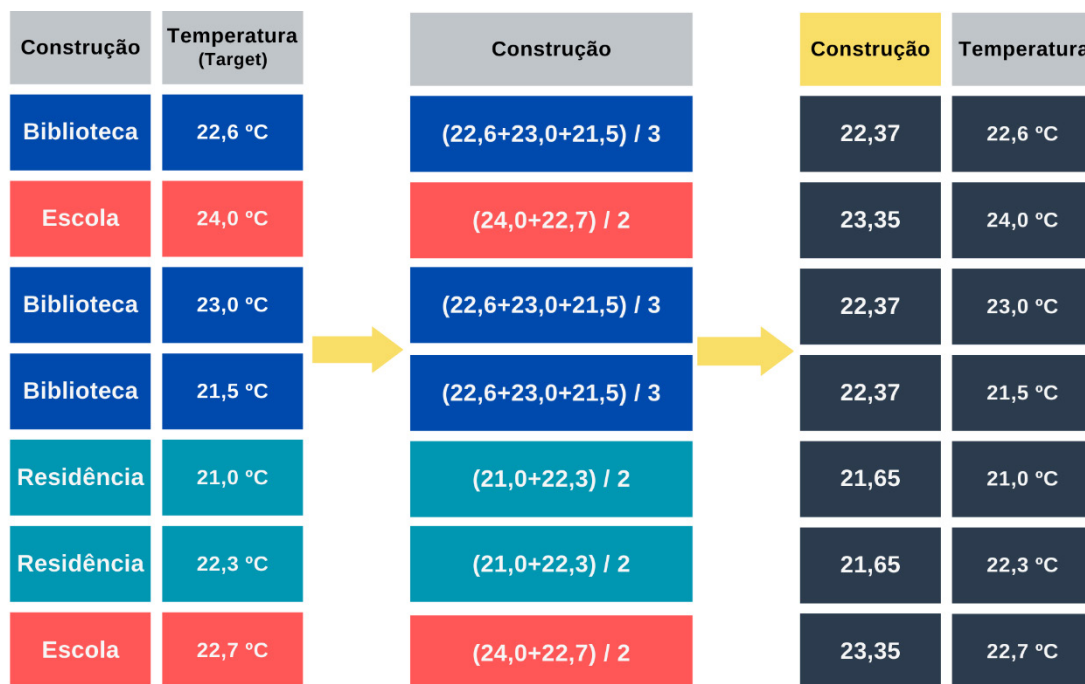
O codificador de alvo (*target encoder*) é o processo de substituição de um valor categórico pela média da variável-alvo de todos os pontos de dados pertencentes à categoria a ser transformada (Svideloc, 2020; Möbius, 2021). Por exemplo, em uma análise do comportamento térmico de edificações, como ilustrado na Figura 16, as construções foram categorizadas como biblioteca, escola e residência, e a variável-

alvo foi a temperatura medida. Para todas as instâncias da categoria “biblioteca”, com valores de temperatura de 22,6°C, 23,0°C e 21,5 °C, o número atribuído foi a média desses valores, resultando em 22,3. O mesmo procedimento foi aplicado às demais categorias.

Diferentemente do codificador *One-Hot*, com o codificador de alvo se mantém a dimensão das categorias. Além disso, é de interesse a proporção de determinada categoria com a variável resposta, o que pode facilitar o aprendizado de alguns modelos.

Contudo, o método apresenta limitações. Inicialmente, variáveis diferentes podem receber o mesmo código caso compartilhem médias idênticas da coluna-alvo. O uso da média pode adicionar um viés nos dados, caso haja um desbalanceamento da quantidade de amostras para cada classe. Além disso, a aplicação desse codificador pode resultar em vazamento de informações (*data leakage*) durante o treinamento do algoritmo (Trevisan, 2022), pois se usa valores da variável-resposta na criação do modelo de treinamento (seção 1.10 - Ética e IA). Para contornar isso, pode-se usar a codificação por exclusão de instância (*leave-one-out encoding*), que é semelhante à codificação de alvo, mas para cada linha, o valor médio da categoria é calculado excluindo a própria observação (vide mais sobre essa estratégia na seção 1.8 - Validação do Modelo).

Figura 16 - Codificador de alvo



Fonte: Autores.

Gnat (2021) e Pita (2023) utilizaram o método dos codificadores de dados-alvos para a codificação de variáveis categóricas durante a avaliação de preços de propriedades imobiliárias. Ambos os autores observaram que essa técnica obteve os melhores resultados entre os conjuntos de técnicas de codificação avaliados.

1.6.2.2 Codificador James-Stein

Por fim, o codificador James-Stein, assim como o codificador de dados-alvo, traz informações da variável-resposta, mas considera uma média ponderada para o número de instâncias de cada categoria, conforme determinado pela Equação 3, de modo a contornar o problema de desbalanceamento entre as categorias (Fontelles, 2020).

$$JS_i = \left(1 - \frac{\sigma^2(y_i)}{\sigma^2(y_i) + \sigma^2(y)}\right) \times \text{média}(y_i) + \left(\frac{\sigma^2(y_i)}{\sigma^2(y_i) + \sigma^2(y)}\right) \times \text{média}(y) \quad \text{Equação 3}$$

onde:

JS_i = Variável qualitativa codificada por *James-Stein*;

$\sigma^2(y_i)$ = Variância da classe que se deseja codificar;

$\sigma^2(y)$ = Variância de todas as variáveis;

$\text{média}(y_i)$ = Média da classe que se deseja codificar;

$\text{média}(y)$ = Média de todas as variáveis.

A Figura 17 compara os resultados do Codificador de Dados-Alvo e o de James-Stein, no exemplo do comportamento térmico de edifícios. Apesar de os códigos gerados serem semelhantes, diferenças mais significativas podem surgir em bancos de dados com maior dispersão entre os valores.

Figura 17 - Codificador James-Stein

Construção	Temperatura (Target)	Construção	James-Stein Encoding	Target Encoding
Biblioteca	22,6 °C	Biblioteca	22,40	22,37
Escola	24,0 °C	Escola	22,93	23,35
Biblioteca	23,0 °C	Biblioteca	22,40	22,37
Biblioteca	21,5 °C	Biblioteca	22,40	22,37
Residência	21,0 °C	Residência	22,02	21,65
Residência	22,3 °C	Residência	22,02	21,65
Escola	22,7 °C	Escola	22,93	23,35

Fonte: Autores.

1.7 Redução de Dimensionalidade

1.7.1 Definição e tipos de estratégias

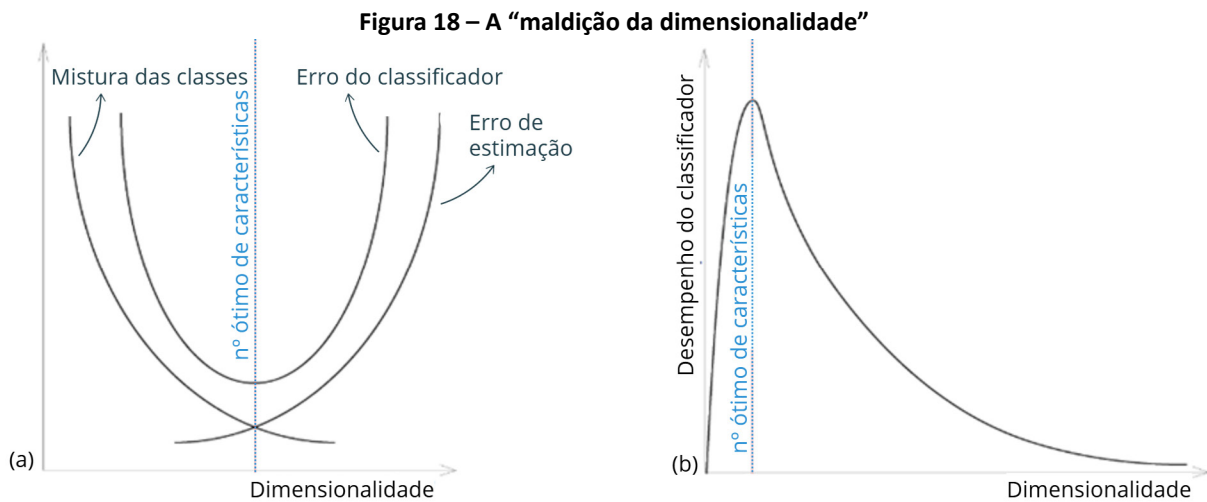
Uma das formas mais eficazes de redução de dados é a redução da dimensionalidade. As dimensões dos dados se referem ao número de características avaliadas para cada observação (Aleysha; Hanif; Talib, 2020). A redução de dimensionalidade é o processo de diminuir o número de variáveis em um modelo de aprendizado, com a premissa de que variáveis redundantes podem ser removidas sem perda de informação relevante (Aleysha; Hanif; Talib, 2020; Barros, 2024). Um exemplo disso é reduzir uma esfera de três dimensões para um círculo de duas dimensões.

Em um exemplo prático, o próximo capítulo desse livro traz uma revisão de estudos de AM aplicados à precificação de imóveis. Os autores listaram 26 características/variáveis frequentemente analisadas para estimar o valor de um imóvel com base em seus atributos locais, financeiros e físicos. Entre as variáveis locais destacam-se localização, conveniência, latitude, longitude, CEP, distância ao centro, orientação, população da cidade e vista. No grupo das variáveis financeiras, estão o valor do condomínio, impostos e o preço por área. Já entre as variáveis físicas, incluem-se a área do imóvel, número de quartos, idade, número de banheiros, andar, tipo (ex.: comercial, residencial unifamiliar, residencial multifamiliar), número de vagas, número de andares, elevadores, padrão de acabamento, aquecedor, piscina e idade pós-reforma. Observa-se que muitas variáveis são funções ou estão relacionadas umas com as outras (ex.: latitude, longitude e distância ao centro; número de vagas e padrão de acabamento; área do imóvel, CEP e impostos). Após uma análise dos próprios dados, Pita (2023) descobriu que o uso de apenas 11 atributos (tipo, região, CEP, número de quartos, número de banheiros, número de vagas, tipo de vaga, posição, estado, tipo de piso e área), gerava as melhores previsões de preço, a um custo computacional satisfatório.

Surge, então, a questão do número ideal de características, pois trabalhar com dados de alta dimensão é desafiador. Na medida em que o número de dimensões aumenta, os dados tornam-se mais esparsos, o volume do espaço de busca cresce exponencialmente e muitos algoritmos perdem eficiência e precisão. Esse dilema é conhecido como “maldição da dimensionalidade” (Barros, 2024), ilustrado na Figura 18.

A Figura 18a mostra que, até um certo limite, o aumento da dimensionalidade reduz a mistura entre as classes, tornando o modelo capaz de categorizar com maior precisão. Entretanto, com muitas dimensões, as diferenças entre as classes podem se tornar menos perceptíveis, dificultando a criação de um modelo eficiente para separá-las (Costa; Cesar, 2018). Após o número ótimo de características, o erro de

estimação aumenta devido ao maior número de características a serem avaliadas, enquanto o erro do classificador se intensifica, pois, a classificação se torna mais rigorosa e menos flexível sem contar que aumenta muito o custo computacional do modelo (Figura 18b).



Fonte: Adaptado de (Saltelli, Puy Fiore, 2024).

Existem diversas técnicas de redução de dimensionalidade que podem ser aplicadas para eliminar características irrelevantes e redundantes. As duas abordagens principais são a seleção de características (*feature selection*) e extração de características (*feature extraction*) (Aleysha; Hanif; Talib, 2020). A seleção de características mantém, no conjunto de dados, apenas as variáveis mais relevantes e descarta as menos informativas ou redundantes, sem criar novas variáveis. A extração de características transforma os dados originais em um novo conjunto de variáveis de dimensão reduzida, combinando ou reformatando as informações existentes. A escolha adequada da técnica pode trazer benefícios significativos, como redução de custo operacional, redução de sobreajuste, tratamento de multicolinearidade, remoção de ruídos de dados, compressão de imagens e transformação de dados não lineares em problemas linearmente separáveis (Pramoditha, 2021).

A multicolinearidade ocorre quando duas ou mais variáveis independentes estão altamente correlacionadas entre si. Isso pode ocorrer por redundância nas variáveis (ex.: área construída, região e valor do IPTU em um modelo de precificação de imóveis, dado que o IPTU é geralmente proporcional às duas variáveis anteriores), por dependência matemática (ex.: temperatura em Celsius e em Fahrenheit) e grandezas que são sabidamente correlacionadas (ex.: teor de carbono e dureza em um modelo de previsão de resistência do aço). Como consequência, a multicolinearidade pode causar instabilidade nos coeficientes do modelo, dificultando a interpretação dos efeitos individuais das variáveis e comprometendo a precisão das previsões. Por isso, quando reduzimos a dimensão, podemos prevenir esse problema.

1.7.2 Seleção de características

Uma abordagem inicial consiste em selecionar, com base em critérios específicos, os atributos mais relevantes para o desempenho do método do modelo em uso. Essa técnica, denominada seleção de características, é eficaz para eliminar redundâncias e atributos irrelevantes, além de mitigar o sobreajuste. Ela também contribui para o aumento da interpretabilidade, dado que modelos com menos variáveis são mais fáceis de entender e analisar (mais sobre essa importante questão na seção 1.10 - Ética e IA). Os métodos de seleção de características são classificados em três categorias principais: filtro, envoltória e integrado.

Métodos do tipo filtro: avaliam os atributos de forma independente do modelo de aprendizado (antes do treinamento), baseando-se em critérios estatísticos. As variáveis são ranqueadas, e as mais relevantes são selecionadas enquanto as demais são descartadas. Essa abordagem é eficiente para lidar com grandes volumes de dados devido ao seu baixo custo computacional. Contudo, não considera os impactos diretos dos atributos selecionados no modelo. As principais técnicas de filtragem são correlação (Pearson, Spearman, Kendall), qui-quadrado (*chi-square test*), informação mútua (*mutual information*) e variância baixa (*low variance filtering*).

Métodos do tipo envoltória (ou invólucro): utilizam o desempenho do classificador para avaliar subconjuntos de atributos, selecionando aqueles que maximizam a precisão de uma técnica de aprendizado específica. Apesar de mais precisos, esses métodos apresentam alto custo computacional, devido à necessidade de múltiplas iterações de treinamento (Berahmand; Nasiri; Forouzandeh, 2021). Além disso, podem perder capacidade de generalização em casos de amostras limitadas (Berahmand; Nasiri; Forouzandeh, 2021). Exemplos de técnicas: seleção recursiva de atributos (*recursive feature elimination*), busca exaustiva (*exhaustive search*) e busca sequencial (*forward/backward selection*).

Métodos embutidos ou integrados: integram a seleção de atributos ao processo de treinamento, realizando ambas as etapas simultaneamente. Eles penalizam variáveis irrelevantes na própria otimização do algoritmo, o que otimiza a eficiência global do modelo. Exemplos de técnicas: Regressão Lasso (*L1 Regularization*); Árvores de Decisão e Florestas Aleatórias (pois calculam a importância de cada atributo automaticamente).

1.7.3 Extração de características

Entre as técnicas de extração de características pode-se citar a Análise de Componentes Principais (*Principal Component Analysis - PCA*), que reduz a dimensionalidade criando novas variáveis (componentes principais) que explicam a maior parte da variabilidade dos dados (melhor detalhada a seguir); a Análise de Componentes Independentes (*Independent Component Analysis*), que separa sinais

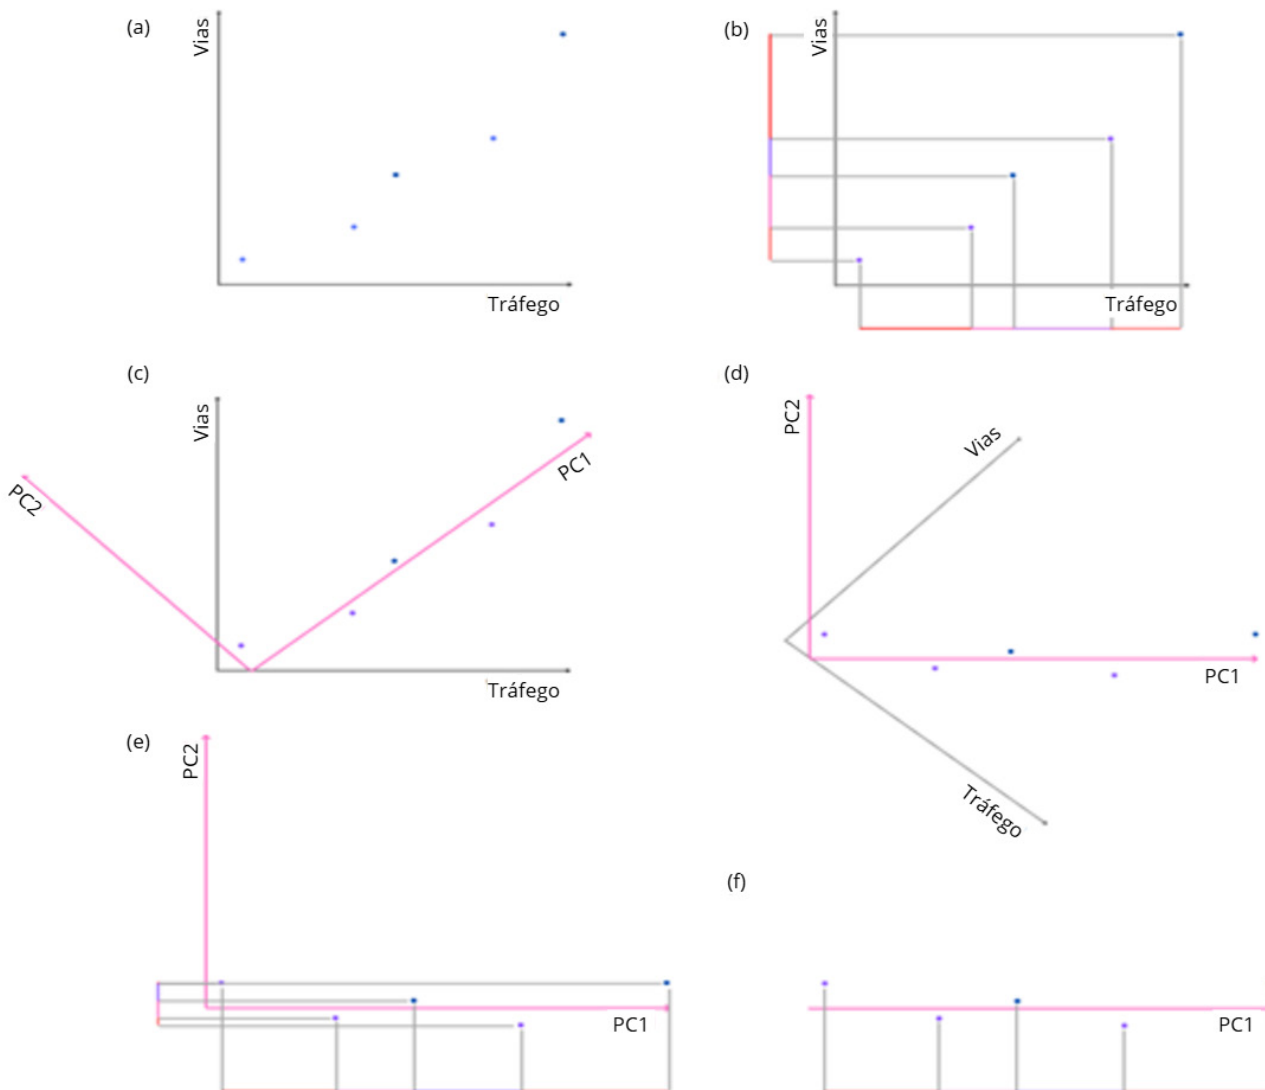
misturados em componentes estatisticamente independentes; e os *Autoencoders*, um tipo de rede neural que aprende a codificar os dados de entrada em uma representação de dimensão inferior e, em seguida, decodificá-los de volta para os dados originais, também utilizado para comprimir dados (Redução de dados).

1.7.3.1 *Análise de Componentes Principais (PCA)*

A PCA é uma das principais ferramentas usadas para reduzir a dimensionalidade dos dados, assumindo que as características são correlacionadas. O PCA utiliza decomposição espectral, transformando os dados de cada observação em um subespaço de menor dimensão (Marukatat, 2022). O resultado é um novo conjunto de dados, em que as observações possuem variáveis derivadas das características originais, mas não correlacionadas entre si. As primeiras componentes principais (PCs) retêm a maior parte da variância dos dados (Moeini et al., 2023). A quantidade de PCs gerada é igual ao número de características originais (Moeini et al., 2023). O principal objetivo da PCA é identificar padrões nos dados e reduzir a quantidade de variáveis mantendo a maior parte da informação, o que melhora a eficiência computacional.

A Figura 19 ilustra o processo de redução de dimensionalidade usando a PCA em um conjunto de dados com duas características, representando o volume de tráfego e o número de vias de rodovias. Na Figura 19 (a), as observações são projetadas de acordo com suas características. Na parte (b), observa-se a variância das observações conforme cada característica. Ao realizar uma rotação dos eixos (c), forma-se uma nova configuração que descreve melhor a variância entre os dados. A partir da parte (d), os novos eixos, ou PCs, são utilizados para representar a variância, com a PC1 explicando a maior parte da variação dos dados, como mostrado na parte (e). A PC2, com menor variância, pode ser descartado (f), resultando em uma redução da dimensionalidade. Nesse exemplo, o volume de tráfego e o número de vias estão fortemente correlacionados, podendo ser expressos por uma única variável, reduzindo a dimensionalidade. É importante observar que, à medida que a dimensionalidade aumenta, a visualização gráfica se torna difícil ou impossível, mas a PCA pode ser aplicado a conjuntos de dados com numerosas características.

Figura 19 – Explicação gráfica do processo de redução de dimensionalidade com o uso de PCA




Fonte: Autores.

1.7.3.2 Dicas para utilizar a PCA

O grau de redução de dimensionalidade na PCA é regido pela variância acumulada pelos PCs (Rahman et al., 2024). Na literatura, o número ideal de PCs varia entre 70-90% de variância acumulada, dependendo do desempenho do modelo e de outros fatores (Costa; Cesar Jr., 2018). A Figura 20 exemplifica essa análise: a partir de 103 características originais, 12 PCs acumulam cerca de 70% da variância, e 19 PCs acumulam 80%. Porém, a partir de 19 PCs, a variância adicional exige muitas PCs, o que pode ser ineficiente em termos de custo computacional. Para melhorar o desempenho do modelo, pode-se testar o uso de mais PCs, atingindo-se até 90% de variância com menos de 50% das PCs totais.

Figura 20 – Exemplo de análise de variância acumulada dos PCs de um modelo



Fonte: Autores.

Outro ponto crucial é a padronização dos dados. Para usar PCA, recomendando-se normalizar as características (seção 1.5.3.1 - Normalização) para evitar que a escala de algumas influencie a análise de variância (Wang, 2024). Também é importante estar atento(a) caso a PCA reduza drasticamente a dimensionalidade para apenas 1 ou 2 PCs. Nesse caso, apesar da reduzida quantidade de variáveis ser ocasionalmente útil para visualização exploratória, todas as outras direções de variância dos dados estão sendo descartadas. Isso pode resultar na perda de características importantes, que poderiam ser essenciais para a tarefa. Por exemplo, em um conjunto de dados de ligas metálicas com 10 variáveis químicas, as duas primeiras componentes principais podem explicar apenas 70% da variância. Ao ignorar os 30% restantes, o modelo pode perder nuances importantes para prever a variável-alvo, como a resistência ao calor.

1.8 Validação do Modelo

A validação é uma técnica essencial para avaliar a capacidade de generalização de um modelo de AM e AP a partir de dados, especialmente em problemas de predição. Ela permite ajustar o modelo e seus hiperparâmetros para evitar sobreajuste ou subajuste, buscando a configuração mais adequada ao problema (Saviotto, 2021). A validação estima a precisão do modelo em novos dados, refletindo seu desempenho prático (Janos, 2022).

Existem inúmeros tipos de validação, dos quais detalharemos a validação simples (*hold-out*); validação cruzada (*k-fold*); o *k-fold* estratificado; o *leave-p-out* e a

sua versão particular *leave-one-out*, e o *bootstrap*. Para exemplificar esses métodos nas próximas seções, vamos utilizar o clássico banco de dados de Iris de Ronald Fisher, de 1936, assumindo, para maior didática, apenas 2 categorias: íris setosa e íris versicolor (Figura 21).

Figura 21 – Excerto do conjunto de dados de classificação de flores de íris

	Comprimento da sépala	Altura da sépala	Comprimento da pétala	Altura da pétala	Espécie
1	5,1	3,5	1,4	0,2	Setosa
2	4,9	3,0	1,4	0,2	Setosa
3	4,7	3,2	1,3	0,2	Setosa
4	7,0	3,2	4,7	1,4	Versicolor
5	6,4	3,2	4,5	1,5	Versicolor
6	6,9	3,1	4,9	1,5	Versicolor
7	5,5	2,3	4,0	1,3	Versicolor
8	6,5	2,8	4,6	1,5	Versicolor
9	5,7	2,8	4,5	1,3	Versicolor

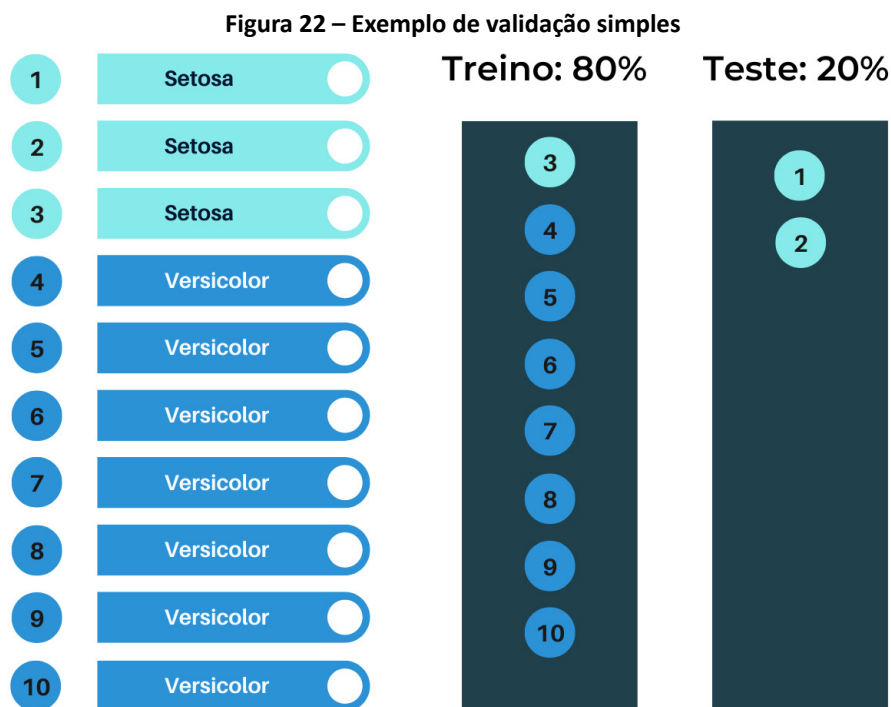
Fonte: Autores, baseado em (Fisher, 1936).

1.8.1 Validação simples

A validação simples ou método *hold-out* é a abordagem mais elementar para validar um modelo, consistindo em dividir aleatoriamente os dados em dois conjuntos: um para treinamento e outro para teste. Geralmente, cerca de 30% dos dados são reservados para teste (Saviotto, 2021; Leite, 2020), embora outras proporções possam ser utilizadas. Os dados usados para teste não podem fazer parte do conjunto de treinamento, ou isso configuraria vazamento de dados.

Uma vantagem da validação simples é que os dados de treino e de teste são independentes, e o método precisa ser executado apenas uma vez, reduzindo os custos computacionais. No entanto, ele apresenta desvantagens significativas: i) não há garantia de que os conjuntos de treino e teste sejam representativos da base original, especialmente em bases pequenas ou heterogêneas; ii) pois dados cruciais podem ser alocados no conjunto de teste, prejudicando o treinamento e o desempenho do modelo; iii) a forma de separação influencia diretamente as métricas obtidas (Saviotto, 2021).

A Figura 22 ilustra um exemplo desse problema para um conjunto com 10 instâncias, divididas em 80% e 20% para treino e teste, respectivamente, no qual apenas uma instância de íris setosa foi usada para treino, mas duas apareceram no conjunto de teste. Apesar da maior proporção de dados estar no conjunto de treino, a diversidade esperada não foi atingida. Como o modelo teve poucas instâncias dessa classe para aprender as relações entre as variáveis, ele provavelmente terá problemas para classificar corretamente essas instâncias. Isso evidencia os desafios da aleatoriedade e da limitação de dados na validação simples.



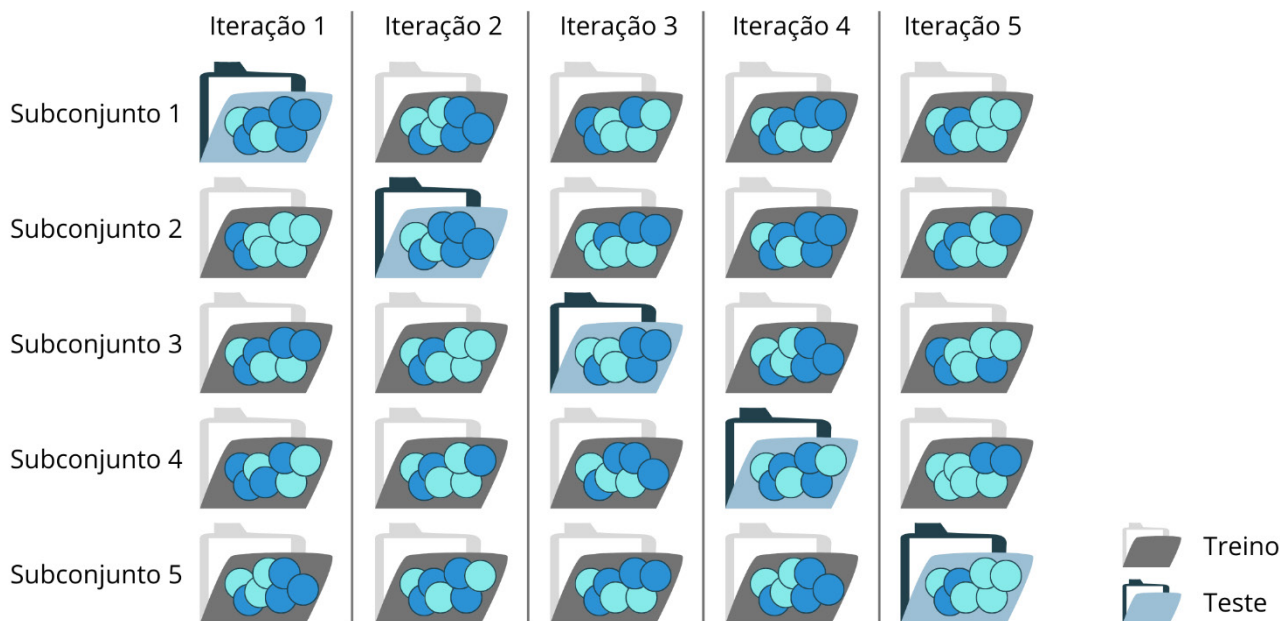
Fonte: Autores.

1.8.2 Validação cruzada *k*-fold

Para mitigar possíveis desbalanceamentos na divisão entre os conjuntos de treino e teste, foi desenvolvida a técnica de validação cruzada *k*-fold (*cross-validation k-fold*). Essa técnica divide aleatoriamente o banco de dados em “*k*” subconjuntos. Em cada iteração, um subconjunto é usado como conjunto de teste, enquanto os demais formam o conjunto de treinamento, repetindo o método de validação simples *k* vezes. A estimativa de erro do modelo é obtida pela média das métricas registradas em todas as *k* iterações.

A Figura 23 ilustra a aplicação do *k*-fold com *k*=5. Por exemplo, em um banco de dados com 200 observações, serão criados 5 subconjuntos de 40 observações cada, e serão realizadas 5 iterações. Em cada iteração, um subconjunto serve como teste, e os demais serão usados previamente para o treinamento.

Figura 23 – Banco de dados dividido em subconjuntos de treino e teste por meio do método k -fold para $k=5$



Fonte: autores

No k -fold, cada observação participa do conjunto de validação uma vez e do conjunto de treinamento $k-1$ vezes, reduzindo viés e variância, já que a maioria dos dados é utilizada em ambos os conjuntos. Essa abordagem avalia como o modelo se comporta diante de variações nos conjuntos de treinamento, minimizando um dos principais problemas da validação simples: a influência da divisão dos dados nas métricas. Contudo, esse método apresenta custos computacionais elevados, pois o modelo precisa ser treinado e testado k vezes em cada passo de validação.

Valores de $k=5$ ou $k=10$ são comumente usados em aplicações de engenharia. Existe uma variação desse método, a validação cruzada com repetição (*repeated k-fold*), em que o processo de particionamento é repetido várias vezes com diferentes divisões.

1.8.3 Validação k -fold estratificada

A validação k -fold estratificada (*stratified k-fold*) consiste em uma pequena variação na técnica de validação cruzada k -fold. Ela é feita de tal forma que cada parte amostral (subconjunto) contém aproximadamente a mesma porcentagem de amostras de cada classe, ou, em caso de problemas de regressão, o valor médio da resposta deve ser aproximadamente igual em todas os subconjuntos (Janos, 2022). Essa técnica assegura o balanceamento dos subconjuntos, evitando um possível desequilíbrio na variável de resposta na separação aleatória.

1.8.4 Validação cruzada *Leave-p-Out* (LpO)

Na validação cruzada *Leave-p-Out* (LpO), p observações são deixadas de fora para validação cruzada. Com n observações, p são reservadas para validação e $(n-p)$ para treinamento do modelo. O método é exaustivo, pois envolve o treinamento e validação para todas as combinações possíveis, o que, usando análise combinatória, resulta em $C_{n,p}$ iterações. Para valores grandes de p , a validação se torna computacionalmente inviável (Janos, 2022). A Figura 24 ilustra a validação de um modelo usando a técnica LpO com um banco de dados Iris de 5 observações e $p = 2$, o que gera 10 combinações possíveis para iteração.

Figura 24 – Exemplo de *Leave-p-Out* com 5 observações e $p = 2$



Fonte: autores

Na Figura 24, observa-se que todas as combinações possíveis para separar duas observações como conjunto de teste foram abrangidas. Essas combinações foram facilmente ilustradas devido ao pequeno valor de n e p . Para um banco de dados com 100 observações, por exemplo, se 30 observações fossem reservadas para validação, o método LpO exigiria 3×10^{25} iterações, evidenciando como o método LpO pode se tornar computacionalmente inviável para valores elevados de n e p .

1.8.5 Validação cruzada *Leave-one-Out* (LoO)

A validação cruzada *leave-one-out* (LoO) é um caso particular do *leave-p-out*, em que $p = 1$. Em cada iteração, uma única observação é usada para teste, enquanto as demais são utilizadas para treinamento. Este método é frequentemente preferido em relação ao LpO, pois não exige cálculos intensivos, já que o número de combinações possíveis é igual ao número de observações n da amostra original. Esse método também é interessante quando o conjunto de dados tem poucas instâncias, dado que todo o conjunto, com a exceção de uma única instância, serão usados para o treinamento em cada iteração. Isso maximiza o potencial de aprendizado do modelo.

1.8.6 Bootstrap

O método *Bootstrap* é uma técnica de reamostragem iterativa com reposição, onde amostras são construídas por observações extraídas aleatoriamente de uma grande base de dados. O modelo é treinado em cada amostra e testado nos dados que não foram escolhidos (*out-of-bag samples*). Após serem escolhidas, as observações retornam ao banco de dados, permitindo que uma mesma observação apareça várias vezes em uma amostra. O(a) desenvolvedor(a) pode definir o tamanho da amostra e o número de repetições da reamostragem (Brownlee, 2018). A Figura 25 ilustra um exemplo simplificado do método *Bootstrap* com um banco de dados de 6 observações e uma amostra de 5 observações para treino.

Figura 25 – *Bootstrap*: exemplo simplificado para um conjunto de teste = 5



Fonte: Autores.

Essa estratégia também é útil quando existem poucos dados, mas, por outro lado, ela pode gerar conjuntos de treinamento com amostras repetidas demais. O número de repetições deve ser suficientemente grande para garantir a confiabilidade das estatísticas, sendo recomendado no mínimo 30 repetições.

1.9 Avaliação da previsão do modelo

A avaliação de um modelo de AM ou AP consiste em medir seu desempenho em relação a um objetivo específico, utilizando métricas que quantificam sua capacidade de fazer previsões ou identificar padrões corretamente. Esse processo é crucial para verificar se o modelo atende aos requisitos do problema e pode ser confiavelmente aplicado em cenários reais. A avaliação pode envolver a análise de erros, acurácia, generalização, entre outros critérios, dependendo do tipo de aprendizado e da natureza dos dados.

A avaliação de modelos é mais comum e direta em problemas de aprendizado supervisionado, devido à presença de rótulos ou valores reais que permitem comparar as previsões com os resultados esperados. Este tipo de avaliação será abordado com mais detalhes a seguir. Para outros tipos de modelo, como em problemas de agrupamento, métricas como a distância intra e inter-agrupamento (intra e inter-cluster) podem ser usadas para avaliar a qualidade dos grupos formados (José; Das, 2022).

1.9.1 Métricas para modelos de classificação

As métricas de modelos de classificação são tipicamente avaliadas de acordo com a matriz de confusão, uma tabela que mostra os acertos e erros do modelo em comparação com os resultados reais das observações. Sua diagonal principal contém os acertos, enquanto os outros valores representam os erros. O caso binário, o mais comum, é ilustrado na Figura 26. Vale destacar que, em vez de negativo/positivo, poderiam ser usados termos como sim/não ou verdadeiro/falso. Com a contagem desses valores, é possível calcular as métricas de avaliação das previsões. A matriz de confusão envolve 4 grandezas:

- **VP - Verdadeiros Positivos:** são acertos do modelo, nos quais ele previu algo como positivo e de fato é positivo;
- **FN - Falsos Negativos:** são erros do modelo, nos quais ele previu algo como negativo quando o valor real era positivo;
- **FP - Falsos Positivos:** são erros do modelo, nos quais ele previu algo como positivo quando o valor real era negativo;
- **VN - Verdadeiros Negativos:** são acertos do modelo, nos quais ele previu algo como negativo e realmente era negativo.

Figura 26 – Matriz de Confusão

		Valor Predito	
		Negativo	Positivo
Valor Real	Negativo	VN	FP
	Positivo	FN	VP

Fonte: Autores.

Nas seções a seguir, introduziremos 5 métricas comumente adotadas, mas que não esgotam todas as existentes: acurácia, precisão, *recall*, F1-Score e especificidade.

Para problemas multiclasse, geralmente adapta-se as métricas a seguir por estratégia “um contra todos” (*one-vs-all*), gerando métricas para cada classe. A seguir, pode-se fazer correlações entre as métricas de cada classe, como médias e médias ponderadas.

1.9.1.1 Acurácia

A acurácia (*accuracy*) é uma métrica simples que indica a performance geral do modelo. Ela envolve a razão entre a soma dos valores acertados (verdadeiros positivos e negativos) pelo total de classificações (Equação 4) (Vilela Jr. et al., 2022).

$$\text{Acurácia} = \frac{VP + VN}{(VP + VN + FP + FN)} \quad \text{Equação 4}$$

Por exemplo, em um modelo com 100 observações para prever se um paciente tem HIV, o modelo prevê corretamente que 89 pacientes não têm HIV e de fato não têm, e 1 paciente que tem HIV é corretamente previsto como positivo. No entanto, o modelo erra ao prever que 2 pacientes têm HIV quando não têm, e 8 pacientes são erroneamente classificados como negativos, quando na verdade têm HIV. Este caso é ilustrado na Figura 27. Com base na acurácia, o modelo demonstra um bom desempenho, com 90% de acertos.

Figura 27 – Exemplo de matriz de confusão aplicada a 100 classificações

		Valor Predito	
		HIV Negativo	HIV Positivo
Valor Real	HIV Negativo	89	2
	HIV Positivo	8	1

Fonte: Autores.

Entretanto, em problemas com classes desproporcionais, a acurácia pode gerar uma falsa impressão de bom desempenho (Coelho et al., 2022). Isso ocorre quando uma classe é quase 100% acertada pelo modelo, influenciando positivamente a análise global, enquanto outra classe, com pouca representatividade no banco de dados, é negligenciada.

1.9.1.2 Precisão

A precisão (*precision*) avalia, entre todas as classificações como positivas, quantas estão corretas (Coelho et al., 2022). Ela é calculada pela Equação 5, dividindo

o número de verdadeiros positivos pela soma deste número e os falsos positivos. Por exemplo, no modelo para prever se uma pessoa tem HIV, a precisão é de 33%, ou seja, entre as pessoas que o modelo classificou como positivas para HIV, apenas 33% estavam corretas.

$$\text{Precisão} = \frac{VP}{(VP + FP)} \quad \text{Equação 5}$$

A precisão é útil quando os falsos positivos são mais prejudiciais que os falsos negativos. Por exemplo, ao classificar um investimento financeiro como bom, é crucial que o modelo esteja correto, mesmo que ocasionalmente classifique bons investimentos como ruins. Ou seja, o modelo deve ser preciso para evitar considerar um investimento bom quando, na realidade, ele não é.

1.9.1.3 Revogação, recall ou sensibilidade

A revogação, *recall* ou sensibilidade (*sensitivity*) avalia, entre todas as situações de classe positiva real, quantas foram corretamente identificadas. Ele é calculado dividindo-se o número de verdadeiros positivos pela quantidade total de exemplos que pertencem à classe, incluindo os falsos negativos, conforme a Equação 6 (Fränti; Mariescu-Istodor, 2023). Por exemplo, no modelo para prever se uma pessoa tem HIV, o *recall* é de 11%, ou seja, entre as pessoas que realmente têm HIV, o modelo acertou apenas 11% delas.

$$\text{Recall} = \frac{VP}{(VP + FN)} \quad \text{Equação 6}$$

Essa métrica é útil quando os falsos negativos são mais prejudiciais que os falsos positivos, como em modelos de previsão de doenças, onde é mais crítico deixar de identificar alguém que tem a doença do que classificar erroneamente alguém como doente. Essa métrica também é importante para problemas de detecção de falhas críticas, como no monitoramento de integridade estrutural.

1.9.1.4 F1-Score

O *F1-Score* é a média harmônica entre precisão e *recall*, oferecendo uma métrica que analisa ambas as medidas simultaneamente. Ele é calculado conforme a Equação 7 (Fourure et al., 2021).

$$\text{F1-Score} = \frac{2 \times (\text{Precisão} \times \text{Recall})}{\text{Precisão} + \text{Recall}} \quad \text{Equação 7}$$

No exemplo do modelo, o *F1-Score* é de 16,67%, o que indica que tanto a precisão quanto o *recall* estão baixos. Essa métrica é útil quando há a necessidade

de equilibrar as duas métricas, especialmente em contextos em que tanto os falsos positivos quanto os falsos negativos devem ser minimizados.

1.9.1.5 Especificidade

A especificidade (*specificity*) mede a capacidade do modelo em prever corretamente a classe negativa. Ela responde à pergunta: De todos os valores negativos, quantos foram classificados como negativos? É calculada dividindo o número de verdadeiros negativos pela soma dos verdadeiros negativos e falsos positivos, conforme a Equação 8 (Machado et al., 2024).

$$\text{Especificidade} = \frac{VN}{(VN + FP)} \quad \text{Equação 8}$$

No exemplo de avaliação de HIV dado, o modelo acertou 97,8% das classificações negativas, ou seja, entre todos os pacientes que o modelo classificou como negativos, 97,8% estavam corretos. No caso da classificação de doenças, uma alta especificidade evita alarmes falsos, reduzindo estresse e exames desnecessários. No caso de controle de qualidade de produtos, por exemplo, uma alta especificidade evita classificar produtos bons como defeituosos, o que reduziria desperdício e retrabalho.

1.9.2 Métricas para modelos de regressão

Para entender melhor as métricas de modelos de regressão, considera-se o exemplo da Tabela 5. Neste caso, o modelo de regressão prevê o preço de casas com base em duas variáveis: área construída e idade da casa. A Tabela 5 apresenta os preços reais e preditos das casas para algumas observações.

Tabela 5 – Preço real e predito do modelo de regressão de exemplo

Obs.	Preço Real (R\$)	Preço Predito (R\$)
1	300.000	280.000
2	450.000	460.000
3	500.000	520.000
4	600.000	590.000
5	700.000	710.000

Fonte: Autores.

Vamos abordar aqui o cálculo do Coeficiente de Correlação de Pearson (r ou R), Coeficiente de Determinação (R^2), Erro Médio Absoluto (MAE), Erro Percentual Absoluto Médio (MAPE), Erro Quadrado Médio (MSE) e Raiz do Erro Quadrado Médio (RMSE). Destes, o R^2 é a métrica mais comumente adotada e amplamente utilizada para se comparar diferentes modelos. Além destes, existem também: Mediana do Erro


Absoluto, Erro Máximo, Erro Relativo Médio, Erro Relativo Absoluto, Erro Quadrático Relativo, Índice de Concordância de Willmott, entre outros. Nem todas as métricas podem ou devem ser utilizadas em qualquer situação. O(A) desenvolvedor(a) deve compreender a função de cada métrica e adotar apenas aquelas que fazem sentido em relação ao seu problema. Adotar métricas utilizadas em outros trabalhos similares pode ser útil para a realização de comparações futuras, mas essa escolha precisa ser feita de maneira criteriosa.

1.9.2.1 Coeficiente de Correlação de Pearson (r ou R)

O coeficiente de correlação de Pearson (r ou R) é uma medida que expressa o grau de relação linear entre duas variáveis quantitativas, com valores variando entre -1 e 1. Quando o coeficiente se aproxima de 1, isso indica uma relação linear positiva, ou seja, na medida em que uma variável aumenta, a outra também tende a aumentar. Por outro lado, quando o coeficiente se aproxima de -1, as variáveis continuam correlacionadas, mas com uma relação inversa, onde o aumento de uma variável está associado à diminuição da outra. O coeficiente de correlação é calculado pela Equação 9, que leva em consideração os desvios entre os valores reais (y_i) e preditos (\hat{y}_i) em relação à média dos valores reais e preditos (\bar{y} e $\bar{\hat{y}}$), ao longo do conjunto de observações. A Figura 28 apresenta uma demonstração gráfica da correlação de duas variáveis.

Figura 28 – Demonstração gráfica da correlação de duas variáveis

$$r = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \cdot \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \quad \text{Equação 9}$$



Fonte: Autores.

Ao calcular o coeficiente de correlação para o caso de exemplo, obtém-se (vide Tabela 6 e Equação 10), o que indica uma forte correlação positiva entre as variáveis. Esse valor sugere que há uma relação linear muito forte entre os valores preditos e os valores reais, indicando que o modelo está fazendo previsões alinhadas com os resultados observados.

Tabela 6 – Processo de cálculo do coeficiente de correlação (r)

Obs.	Preço Real (y)	Preço Predito (\hat{y})	$y - \bar{y}$	$\hat{y} - \bar{\hat{y}}$	$(y - \bar{y})(\hat{y} - \bar{\hat{y}})$	$(y - \bar{y})^2$	$(\hat{y} - \bar{\hat{y}})^2$
1	300.000	280.000	-210.000	-232.000	48.720.000.000	44.100.000.000	53.824.000.000
2	450.000	460.000	-60.000	-52.000	3.120.000.000	3.600.000.000	2.704.000.000
3	500.000	520.000	-10.000	8.000	-80.000.000	100.000.000	64.000.000
4	600.000	590.000	90.000	78.000	7.020.000.000	8.100.000.000	6.084.000.000
5	700.000	710.000	190.000	198.000	37.620.000.000	36.100.000.000	39.204.000.000
Média	510.000 (\bar{y})	512.000 ($\bar{\hat{y}}$)		Soma	96.400.000.000	92.000.000.000	101.880.000.000

Fonte: Autores.

$$r = \frac{96.400.000.000}{\sqrt{92.000.000.000 \cdot 101.880.000.000}} = 0,9957 \quad \text{Equação 10}$$

1.9.2.2 Coeficiente de Determinação (R^2)

O R^2 ou coeficiente de determinação é um indicador utilizado para medir a qualidade do ajuste de um modelo de regressão. Ele calcula a porcentagem da variação dos dados que pode ser explicada pelo modelo, ou seja, quanto das medições reais podem ser previstas com base nas previsões feitas pelo modelo. O valor do R^2 geralmente varia entre 0 e 1, sendo que valores próximos de 1 indicam que o modelo analisado se ajusta muito bem aos dados, ou seja, que os preditores são capazes de explicar bem a variabilidade dos dados. No entanto, em alguns casos, o R^2 pode ser negativo, o que indica que o modelo não é eficaz e que a média dos valores reais seria uma melhor previsão do que o modelo adotado. O R^2 pode ser calculado pela Equação 11, em que y_i representa os valores reais, \bar{y} a média dos valores reais e \hat{y}_i os valores preditos pelo modelo.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad \text{Equação 11}$$

No exemplo do preço de casas, o R^2 (vide Tabela 7 e Equação 12), o que significa que 98,80% da variação no preço das casas pode ser explicada pelas variáveis do modelo (área e idade das casas), enquanto os 1,20% restantes são atribuídos a fatores não considerados pelo modelo.

Tabela 7 – Processo de cálculo do coeficiente de determinação (R²)

Obs.	Preço Real (y)	Preço Predito (ŷ)	y - ȳ	(y - ŷ) ²	(y - ȳ) ²
1	300.000	280.000	-210.000	400.000.000	44.100.000.000
2	450.000	460.000	-60.000	100.000.000	3.600.000.000
3	500.000	520.000	-10.000	400.000.000	100.000.000
4	600.000	590.000	90.000	100.000.000	8.100.000.000
5	700.000	710.000	190.000	100.000.000	36.100.000.000
Média	510.000 (ȳ)		Soma	1.100.000.000	92.000.000.000

Fonte: Autores.

$$R^2 = 1 - \frac{1.100.000.000}{92.000.000.000} = 0,9880 \quad \text{Equação 12}$$

1.9.2.3 Erro Médio Absoluto (MAE)

O erro médio absoluto (*Mean Absolute Error – MAE*) calcula a média das distâncias absolutas entre os valores preditos e os valores reais. Ao contrário de outras métricas, o MAE não penaliza de forma severa os *outliers* (valores atípicos, bem distantes dos demais), o que pode ser vantajoso em certos contextos. Essa métrica possui um valor mínimo de 0, o que indica um modelo perfeito (sem erro), mas não tem um valor máximo, já que o erro pode crescer indefinidamente. O MAE é calculado pela Equação 13, em que y_i representa os valores reais e \hat{y}_i os valores preditos para as $i = 1, 2, \dots, n$ observações.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \text{Equação 13}$$

No exemplo dos preços das casas, o MAE obtido foi de R\$ 14.000 (vide Tabela 8 e Equação 14), o que significa que, em média, o modelo comete um erro de R\$ 14.000 em suas previsões de preço. A desvantagem desse método é a falta de relatividade com os dados: R\$ 14.000 é um erro muito grande? Talvez seja um erro pequeno para imóveis na faixa de R\$ 700.000, mas pode ser um erro relativamente grande para imóveis de R\$300.000. Para sanar essa dúvida, usa-se o erro percentual absoluto médio (MAPE), a seguir.

Tabela 8 – Processo de cálculo do erro médio absoluto (MAE)

Obs.	Preço Real (y)	Preço Predito (\hat{y})	$ y - \bar{y} $
1	300.000	280.000	20.000
2	450.000	460.000	10.000
3	500.000	520.000	20.000
4	600.000	590.000	10.000
5	700.000	710.000	10.000

Fonte: Autores.

$$\text{MAE} = \frac{70.000}{5} = 14.000 \quad \text{Equação 14}$$

1.9.2.4 Erro Percentual Absoluto Médio (MAPE)

O erro percentual absoluto médio (*Mean Absolute Percentage Error - MAPE*) expressa a precisão do modelo em termos percentuais. Ele é obtido pela divisão da diferença entre os valores preditos e reais pelo valor real de cada instância. Por isso, o MAPE é útil para calcular o desvio em relação à ordem de grandeza dos valores avaliados. Quanto menor o valor do MAPE, mais preciso será o modelo de regressão. O MAPE pode ser calculado de acordo com a Equação 15, em que y_i representa os valores reais e \hat{y}_i os valores preditos para as $i = 1, 2, \dots, n$ observações.

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad \text{Equação 15}$$

Por ser expresso em porcentagem, essa métrica é bastante intuitiva. No caso do modelo de previsão de preço de casas, o MAPE é de 3,20% (vide Tabela 9 e Equação 16), o que significa que, em média, o modelo apresenta um erro de 3,20% em relação aos valores reais. O MAPE é útil para comparar a qualidade de modelos com função similar (ex.: precificação de imóveis), mas que lidam com bancos de dados de escalas muito diferentes (ex.: imóveis de padrão popular e imóveis de luxo).

Tabela 9 – Processo de cálculo do erro percentual médio absoluto (MAPE)

Obs.	Preço Real (y)	Preço Predito (\hat{y})	$ y - \bar{y} $	$\left \frac{\hat{y} - y}{y} \right $
1	300.000	280.000	20.000	0,0667
2	450.000	460.000	10.000	0,0222
3	500.000	520.000	20.000	0,0400
4	600.000	590.000	10.000	0,0167
5	700.000	710.000	10.000	0,0143
			Soma	0,1598

Fonte: Autores.

$$\text{MAPE} = \frac{100\% \times 0,1598}{5} = 3,20\% \quad \text{Equação 16}$$

1.9.2.5 Erro Quadrático Médio (MSE)

O erro quadrático médio (*Mean Squared Error – MSE*) calcula a média dos erros do modelo ao quadrado. Isso significa que erros maiores entre os valores reais e preditos são penalizados mais severamente. Da mesma forma que o MAE, quanto maior o valor do MSE, pior o desempenho do modelo, já que ele indica que o modelo está cometendo erros mais significativos. O MSE possui um valor mínimo de 0, o que indicaria um modelo perfeito, e pode crescer indefinidamente. Ele pode ser calculado pela Equação 17, em que y_i representa os valores reais e \hat{y}_i os valores preditos para as $i = 1, 2, \dots, n$ observações.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{Equação 17}$$

Um ponto negativo do uso do MSE é sua falta de interpretabilidade direta. Por exemplo, no caso do modelo de previsão de preço de casas, o MSE foi de R\$²220.000.000 (vide Tabela 10 e Equação 18). Isso significa que a média dos erros quadráticos entre os valores reais e os valores preditos pelo modelo é de 220 milhões de reais ao quadrado, o que torna difícil a interpretação prática dessa métrica em termos de unidades monetárias.

Tabela 10 – Processo de cálculo do erro quadrado médio (MSE)

Obs.	Preço Real (y)	Preço Predito (\hat{y})	$(y - \hat{y})^2$
1	300.000	280.000	400.000.000
2	450.000	460.000	100.000.000
3	500.000	520.000	400.000.000
4	600.000	590.000	100.000.000
5	700.000	710.000	100.000.000
Soma			1.100.000.000

Fonte: Autores.

$$\text{MSE} = \frac{1.100.000.000}{5} = 220.000.000 \quad \text{Equação 18}$$

1.9.2.6 Raiz do Erro Quadrado Médio (RMSE)

A raiz do erro quadrático médio (*Root Mean Squared Error – RMSE*) é uma métrica que visa melhorar a interpretação do MSE, trazendo a unidade de medida

para a mesma escala dos dados originais. Assim como o MSE, o RMSE penaliza previsões que estão muito distantes dos valores reais. Isso é útil para aplicações onde grandes desvios são indesejáveis (ex.: estimativa da resistência à compressão do concreto estrutural). Ele também vai de 0 a infinito e pode ser calculado de acordo com a Equação 19, em que y_i representa os valores reais e \hat{y}_i os valores preditos para as $i = 1, 2, \dots, n$ observações.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \text{Equação 19}$$

No caso do modelo de previsão de preço de casas, o RMSE obtido foi de R\$ 14.832,40 (vide Tabela 10 e Equação 20). Isso significa que, em média, o modelo preditivo comete um erro de R\$ 14.832,40 na estimativa de preços. É útil comparar o RMSE ao MAE (R\$ 14.000). Quando os dois valores são próximos, isso significa que os erros do modelo são distribuídos de forma equilibrada (sem grandes *outliers*) e não há muitos erros extremos que estejam distorcendo a média quadrática.

$$\text{RMSE} = \sqrt{\frac{1.100.000.000}{5}} = 14.832,40 \quad \text{Equação 20}$$

1.10 Ética e IA

1.10.1 Princípios éticos em IA

A aplicação de técnicas de IA vem se expandindo em diversos setores, influenciando desde processos cotidianos, como corretores ortográficos, anúncios personalizados e processos bancários, até o projeto de sistemas de infraestrutura e decisões governamentais. Embora tragam benefícios significativos (Winfield; Jirotko, 2018; Doneda et al., 2018), seu avanço levanta questões éticas, como o uso inadequado de dados, vieses algorítmicos e a responsabilização em sistemas autônomos, como carros (Rossetti; Angeluci, 2021; Mittelstadt et al., 2016). Existe uma falsa percepção de que os modelos de IA são imparciais, por tomarem decisões puramente matemáticas e objetivas. Entretanto, os modelos sempre serão tão imparciais quanto os bancos de dados e as estratégias usadas para sua construção e, nesses casos, há subjetividades e erros humanos.

Os algoritmos de AM e AP, ao serem treinados com dados enviesados, podem perpetuar preconceitos de gênero, raça e outros (Garcia, 2020). A parcialidade pode ser ilustrada pelo caso ocorrido em New Jersey, em 2020, no qual um homem foi erroneamente preso devido a um sistema de reconhecimento facial, que o vinculou a

um furto em um hotel (Zaruvni, 2020). Esse erro foi atribuído a um viés no banco de dados: a falta de dados de pessoas de cor de pele preta para treinamento do algoritmo (Zaruvni, 2020). Outro exemplo envolve o uso de aprendizado de máquina para prever a vencedora de um concurso de beleza, em que o banco de dados privilegiava características associadas à cor de pele branca (Canaltech, 2016). Nesse caso, das 44 pessoas classificadas como belas pelo algoritmo, 36 eram brancas (Canaltech, 2016). Conforme Garcia (2020), esses resultados podem ser erroneamente percebidos como imparciais devido ao respaldo matemático, mas as lacunas no *design* e na compreensão ética podem gerar graves impactos sociais (Mittelstadt et al., 2016).

Contudo, identificar a influência da subjetividade humana no projeto e na configuração de um algoritmo geralmente é complexo e depende de uma investigação multidisciplinar de longo prazo (Mittelstadt et al., 2016; Rossetti; Angeluci, 2021). Existe um grau de incerteza e opacidade sobre como alguns modelos de AM funcionam que também preocupam pesquisadores(as), nos aspectos como (Lopes; Mendes, 2023):

- **Evidências inconclusivas e ações injustificadas:** algoritmos podem gerar decisões baseadas em correlações estatísticas sem relação causal, resultando em ações injustificadas (Mittelstadt et al., 2016; Rossetti; Angeluci, 2021; Doneda et al., 2018). Um exemplo é o caso da agência de crédito SCHUFA, na Alemanha, que penalizava a avaliação de consumidores por buscarem acessar seus próprios dados, critério considerado discriminatório e posteriormente proibido na reforma da Lei de Proteção de Dados de 2009 (Doneda et al., 2018).
- **Evidências incompreensíveis e opacidade:** algoritmos de aprendizado profundo funcionam como “caixas-pretas”, permitindo apenas a observação de entradas e saídas, sem revelar o processo interno, o que dificulta a compreensão de suas decisões (Winfield; Jirotko, 2018). Essa opacidade é defendida por razões de privacidade e competição, mas casos como acidentes fatais com carros autônomos demonstram a necessidade urgente de transparência para garantir responsabilização, confiança social e ética nos sistemas (Stilgoe, 2018; Rossetti; Angeluci, 2021).
- **Evidências equivocadas e os vieses:** a crença de que algoritmos são imparciais é insustentável, pois eles reproduzem os preconceitos presentes nos dados de treinamento (Garcia, 2020; Mittelstadt et al., 2016). Exemplos incluem o Google Fotos, que em 2015 rotulou pessoas negras como gorilas, e o sistema de recrutamento da Amazon, que excluiu mulheres, mostrando como dados enviesados resultam em discriminações automatizadas (Rossetti; Angeluci, 2021; Garcia, 2020).

- **Resultados injustos e discriminação:** as decisões algorítmicas enviesadas, por sua vez, podem resultar em discriminação, como no caso de um sistema de saúde nos EUA que favoreceu pacientes brancos ao selecionar candidatos para tratamento preventivo com base em frequência de uso do sistema, ignorando as barreiras econômicas enfrentadas por pacientes negros (Obermeyer et al., 2019). Ainda na área da saúde, o uso de IA em diagnósticos, como na detecção de melanoma, evidencia esses desafios. A maioria dos algoritmos de dermatologia é treinada apenas ou predominantemente com imagens de pele clara, o que pode comprometer sua eficácia em peles mais escuras, possivelmente resultando em diagnósticos imprecisos (Adamson; Smith, 2018). Esses casos ressaltam como dados enviesados podem amplificar desigualdades sociais (Mittelstadt et al., 2016).
- **Autonomia e privacidade:** os algoritmos de personalização podem limitar a autonomia dos usuários ao manipular as informações apresentadas com base em preferências ou vulnerabilidades, influenciando escolhas em benefício de terceiros (Rossetti; Angeluci, 2021). Um exemplo clássico é o “*feed*” de redes sociais, que mostra para o usuário apenas informações selecionadas pelos algoritmos, cujo funcionamento não é claro e nem regulamentado. Isso pode gerar “bolhas” de polarização ideológica, influenciando decisões em diversos níveis (Spohr, 2017). Além disso, dispositivos como Amazon Echo e Google Home levantam questões sobre privacidade e o acesso a dados pessoais, evidenciando os desafios de proteger informações na era da conectividade (Karale, 2021).
- **Rastreabilidade e a responsabilidade moral:** os algoritmos modernos, especialmente os de aprendizado não-supervisionado, desafiam os modelos tradicionais de rastreabilidade e responsabilidade, já que suas decisões não podem ser completamente previstas ou explicadas (Mittelstadt et al., 2016). No caso de carros autônomos, por exemplo, ainda não há consenso sobre quem é o responsável em situações de acidente, indicando a necessidade de algoritmos projetados para refletir normas éticas e culturais (Winfield; Jirotko, 2018).

1.10.2 Desafios da construção de algoritmos de AM e AP

É crucial que os(as) programadores(as) antecipem e evitem armadilhas que possam comprometer o desempenho e a confiabilidade dos modelos. Destacam-se a seguir os desafios mais comuns, que apresentam riscos distintos e exigem estratégias específicas de mitigação para garantir a eficácia e a aplicabilidade dos modelos de inteligência artificial (NEX Softsys Software Development Company, 2022; Santos et al., 2018; AltexSoft, 2022; Google AI, 2022):

- **Conjunto de dados:** dados de baixa qualidade podem levar a previsões imprecisas ou enviesadas. Esses problemas incluem dados insuficientes, desbalanceados, incompletos ou com *outliers*, exigindo análise criteriosa antes do desenvolvimento do modelo (Google AI, 2022; NEX Softsys Software Development Company, 2022).
- **Sobreajuste (*overfitting*):** o sobreajuste ocorre quando o modelo aprende excessivamente os padrões dos dados de treino, perdendo capacidade de generalização para novos dados. Isso resulta em desempenho inferior no conjunto de teste, comparável a um estudante que decora exercícios específicos sem entender conceitos gerais (Santos et al., 2018; Correa, 2021). Conjuntos de dados com instâncias muito parecidas e divisão desbalanceada entre treino e teste são fatores que podem levar ao sobreajuste. Uma solução eficaz para minimizar o sobreajuste é a validação cruzada *k-fold*, que simula a capacidade de generalização do modelo ao dividir os dados em várias partições aleatórias para testes iterativos (Wagner; Rondinelli, 2016).
- **Sub-ajuste (*underfitting*):** o subajuste acontece quando o modelo não é capaz de capturar padrões relevantes nos dados de treinamento, resultando em desempenho ruim. Esse problema pode ser causado por um conjunto de dados de tamanho ou representatividade insuficiente; pela seleção de técnicas (algoritmos) inadequadas para o problema; pela calibração inadequada dos hiperparâmetros das técnicas adotadas; pela falta ou uso adequado de estratégias de pré-processamento, entre outras.
- **Métricas de avaliação:** a escolha inadequada de métricas pode comprometer a avaliação do desempenho do modelo. Modelos de regressão utilizam métricas como R, R^2 , MSE, MAPE e MAE, enquanto modelos de classificação aplicam precisão, *recall* e *F1-score* (AltexSoft, 2022). Cada técnica tem aplicações específicas, não são comparáveis em muitos casos e não devem ser usadas somente porque outros desenvolvedores(as) as utilizaram. Em dados desbalanceados, métricas simples como a acurácia podem gerar resultados enganosos. Por exemplo, um modelo que classifica corretamente apenas a classe majoritária pode apresentar alta acurácia, mas baixo desempenho real (NEX Softsys Software Development Company, 2022).
- **Vazamento de dados (*data leakage*):** o vazamento de dados ocorre quando informações do conjunto de treino influenciam o conjunto de teste, gerando resultados otimistas que não refletem a capacidade do modelo em generalizar. Isso pode ser comparado a um aluno que estuda com o gabarito da prova: ele pode obter boas notas, mas não está preparado para aplicar o conhecimento em situações reais (Neoway, 2022; Santos et al., 2018). Esse problema comumente acontece no processo de divisão do conjunto de dados

em treino, teste e validação e na transformação de variáveis categóricas com o uso de codificadores.

1.10.3 Melhores práticas

O desenvolvimento e o uso de algoritmos de IA demandam a consideração de implicações legais, éticas e de segurança, refletindo uma necessidade crescente de auditorias algorítmicas, tal como ocorre na área financeira. Segundo Koshiyama et al. (2021), essas auditorias devem garantir a conformidade dos algoritmos em quatro aspectos fundamentais:

- 1) Desempenho e robustez, assegurando a proteção contra adulterações e vulnerabilidades;
- 2) combate ao preconceito e à discriminação, evitando tratamentos injustos;
- 3) interpretabilidade, garantindo que os sistemas sejam compreensíveis para usuários e reguladores;
- 4) privacidade, mitigando vazamentos de dados pessoais.

Complementando esses princípios, o Google AI (2022) propõe práticas de *design* centradas no ser humano, avaliação por métricas variadas, compreensão das limitações dos dados e modelos, além de testes rigorosos para assegurar confiabilidade e usabilidade.

Para assegurar a justiça algorítmica, recomenda-se o uso de dados representativos e balanceados, colaboração interdisciplinar com cientistas sociais e outros especialistas, e análise contínua de vieses e desempenho em cenários reais. Na busca por interpretabilidade, é essencial projetar modelos baseados em entradas relevantes e verificáveis; adotar técnicas interpretáveis quando possível (ex.: regressão linear e árvores de decisão) e envolver os usuários no desenvolvimento para alinhar suas expectativas e necessidades. Em algumas situações, também é possível usar métodos pós-hoc, técnicas usadas para explicar modelos complexos após o seu treinamento. No aspecto da privacidade, orienta-se a coleta responsável e o cumprimento rigoroso de leis e normas, bem como a prevenção contra memorização ou exposição de dados sensíveis pelos modelos.

Por fim, a segurança dos sistemas requer a identificação de ameaças potenciais, o desenvolvimento de estratégias preventivas e a execução de testes adversos. Além disso, é vital manter-se atualizado sobre os avanços em aprendizado de máquina, garantindo que as soluções implementadas continuem robustas frente a novos desafios e oportunidades (Koshiyama et al., 2021; Google AI, 2022; Google AI, 2022).

1.11 Agradecimentos

Agradecemos à UFJF (Universidade Federal de Juiz de Fora) e à UFOP (Universidade Federal de Ouro Preto) pelo apoio institucional. Gostaríamos de expressar nossa gratidão às instituições que ofereceram apoio financeiro para este trabalho: CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior); CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais). Também agradecemos a colaboração do Grupo de Pesquisa em Ciência de Dados Aplicada à Engenharia (CIDENG-CNPq).

1.12 Referências

- ABNT. **NBR 12655 - Concreto de cimento Portland - Preparo, controle, recebimento e aceitação - Procedimento**. [S.l.], 2022.
- ADAMSON, A. S.; SMITH, A. Machine Learning and Health Care Disparities in Dermatology. **JAMA Dermatology**, [S.l.], v. 154, n. 11, p. 1247-1.248, 2018.
- AGRESTI, A. **Categorical Data Analysis**. 3. ed. [S.l.]: Wiley, 2018.
- AHMAD, A. et al. Prediction of Geopolymer Concrete Compressive Strength Using Novel Machine Learning Algorithms. **Polymers**, [S.l.], 2021.
- AHMAD, A. et al. Compressive strength prediction of fly ash-based geopolymer concrete via advanced machine learning techniques. **Case Studies in Construction Materials**, [S.l.], v. 16, 2022.
- AHMED, A. A. et al. Applications of machine learning to water resources management: A review of present status and future opportunities. **Journal of Cleaner Production**, [S.l.], v. 441, p. 140.715, 2024.
- ALABDULLAH, A. A. et al. Prediction of rapid chloride penetration resistance of metakaolin based high strength concrete using light GBM and XGBoost models by incorporating SHAP analysis. **Construction and Building Materials**, [S.l.], 2022.
- ALASADI, S. A.; BHAYA, W. S. Review of Data Preprocessing Techniques in Data Mining. **ARPN Journal of Engineering and Applied Sciences**, [S.l.], 2017.
- ALEXANDROPOULOS, S.-A. N.; KOTSIANTIS, S. B.; VRAHATIS, M. N. Data preprocessing in predictive data mining. **The knowledge review**, [S.l.], 2019.
- ALESHA, S.; HANIF, M. K.; TALIB, R. Overview and comparative study of dimensionality reduction techniques for high dimensional data. **Information Fusion**, [S.l.], v. 59, p. 44-58, 2020.

ALTEXSOFT. **Machine Learning Metrics**: how to measure the performance of a machine learning model, [S.I.], 2022. Disponível em: <https://www.altexsoft.com/blog/machine-learning-metrics/>. Acesso em: 26 set. 2022.

ALVES, V.; CURY, A. A fast and efficient feature extraction methodology for structural damage localization based on raw acceleration measurements. **Struct. Contr. Health Monit.**, [S.I.], v. 28, n. 7, 2021. p. e2748.

AMIN, M. N. et al. Compressive Strength Estimation of Geopolymer Composites through Novel Computational Approaches. **Polymers**, [S.I.], 2022.

ANBARASU, K. et al. Harnessing Artificial Intelligence for Sustainable Bioenergy: Revolutionizing Optimization, Waste Reduction, and Environmental Sustainability. **Bioresource Technology**, [S.I.], 2023. DOI: <https://doi.org/10.1016/j.biortech.2024.131893>.

ANEJA, S. et al. Bayesian Regularized Artificial Neural Network Model to Predict Strength Characteristics of Fly-Ash and Bottom-Ash Based Geopolymer Concrete. **Materials**, [S.I.], 2021.

ANUKIRUTHIKA, T.; JAYAS, D. S. AI-driven grain storage solutions: Exploring current technologies, applications, and future trends. **Journal of Stored Products Research**, [S.I.], 2025. DOI: <https://doi.org/10.1016/j.jspr.2025.102588>.

APARNA, K. G.; SWARNALATHA, R.; MURCHANA, C. Optimizing wastewater treatment plant operational efficiency through integrating machine learning predictive models and advanced control strategies. **Process Safety and Environmental Protection**, [S.I.], v. 188, p. 995-1.008, 2024.

ARACHCHILAGE, C. B. et al. A machine learning model to predict unconfined compressive strength of alkali-activated slag-based cemented paste backfill. **Journal of Rock Mechanics and Geotechnical Engineering**, [S.I.], p. 2.803-2.815, 2023.

ARIF, M. et al. Artificial intelligence and machine learning models application in biodiesel optimization process and fuel properties prediction. **Sustainable Energy Technologies and Assessments**, [S.I.], 2025. DOI: <https://doi.org/10.1016/j.seta.2024.104097>.

ATELIWARE. Feature Engineering: preparando dados para aprendizado de máquina. **Ateliware**, [S.I.], 2021. Disponível em: <https://blog.ateliware.com/feature-engineering/#:~:text=Feature%20Engineering%3A%20preparando%20dados%20para,e%20cria%3%A7%3A%3o%20de%20novas%20features>. Acesso em: 18 nov. 2024.

AWOYERA, P. O. et al. Estimating strength properties of geopolymer self-compacting concrete using machine learning techniques. **Journal of Materials Research and Technology**, [S.l.], v. 9, p. 9.016-9.028, 2020.

BAE, S.; KULCSÁR, B.; GROS, S. Personalized dynamic pricing policy for electric vehicles: reinforcement learning approach. **Transportation Research Part C: Emerging Technologies**, p.104540, 2024. DOI: <https://doi.org/10.1016/j.trc.2024.104540>.

BAG, R. et al. Modelling and mapping of soil erosion susceptibility using machine learning in a tropical hot sub-humid environment. **Journal of Cleaner Production**, [S.l.], v. 364, p. 132.428, 2022.

BAGHERI, A.; CREMONA, C. Formulation of mix design for 3D printing of geopolymers: a machine learning approach. **Materials Advances**, [S.l.], 2020.

BAIA, C. Introdução ao Machine Learning. **Carlos Baía**, 17 jul. 2016. Disponível em: <http://carlosbaia.com/2016/07/17/introducao-ao-machine-learning/>. Acesso em: 19 nov. 2024.

BARROS, A. O que é a Redução de Dimensionalidade? **Aprenda Data Science**, [S.l.], 2024. Disponível em: <https://www.aprendadatascience.com/blog/an%C3%A1lise-explorat%C3%B3ria-de-dados/redu%C3%A7%C3%A3o-de-dimensionalidade>. Acesso em: 19 nov. 2024.

BATISTA, G. **Pré-processamento de Dados em Aprendizado de Máquina Supervisionado**. São Carlos: Universidade de São Paulo, 2003.

BERAHMAND, M. R. K.; NASIRI, E.; FOROUZANDEH, S. Review of swarm intelligence-based feature selection methods. **Engineering Applications of Artificial Intelligence**, [S.l.], 2021.

BERTRAND, J.-M. et al. Technical note: Improving the European air quality forecast of the Copernicus Atmosphere Monitoring Service using machine learning techniques. **Atmospheric Chemistry and Physics**, [S.l.], v. 22, n. 9, p. 5.317-5.333, 2023.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. Cambridge: Springer, 2006.

BOGGIO, A. J. **Estudo comparativo de métodos de dosagem de concretos de cimento Portland**, 2000. Disponível em: <https://lume.ufrgs.br/handle/10183/12575>. Acesso em: 18 nov. 2024

BROWNLEE, J. **A Gentle Introduction to the Bootstrap Method**, [S.l.], 2018. Disponível em: <https://machinelearningmastery.com/a-gentle-introduction-to-the-bootstrap-method/>. Acesso em: 26 set. 2022.

BRUNELLO, A. et al. A survey on recent trends in robotics and artificial intelligence in the furniture industry. **Robotics and Computer-Integrated Manufacturing**, p.102920, 2025. DOI: <https://doi.org/10.1016/j.rcim.2024.102920>.

CANALTECH, R. **Concurso de beleza julgado por AI tem maioria branca como ganhadores**, 2016. Disponível em: <https://youtube.com/shorts/hwrkaOkXno?si=HgFGXxKneCB7L37H>. Acesso em: 7 set. 2022

CAO, R. et al. Application of Machine Learning Approaches to Predict the Strength Property of Geopolymer Concrete. **Materials**, [S.l.], 2022.

CARDOSO, R. A.; CURY, A.; BARBORA, F. A clustering-based strategy for automated structural modal identification. **Struct. Health Monit.**, [S.l.], v. 18, p. 201-217, 2018.

CARVALHO, A. R. D. Occupational Risks in the Technological Development of Construction Materials at Brazilian Public Universities. **Revista de Gestão - RGSA**, São Paulo (SP), v. 18, n. 6, p. e07968, 2024. DOI: 10.24857/rgsa.v18n6-199.

CARVALHO, A. R. D. et al. **Potencial do uso dos resíduos industriais originados no estado de Minas Gerais como precursores geopoliméricos**. In: ENCONTRO NACIONAL DE APROVEITAMENTO DE RESÍDUOS NA CONSTRUÇÃO: CIRCULARIDADE E SUSTENTABILIDADE. Foz do Iguaçu- PR, 2023.

CARVALHO, A. R. D. et al. Proposition of geopolymers obtained through the acid activation of iron ore tailings with phosphoric acid. **Construction and Building Materials**, [S.l.], 2023.

CARVALHO, A. R. et al. Exploratory literature review and scientometric analysis of artificial intelligence applied to geopolymeric materials. **Engineering Applications of Artificial Intelligence**, [S.l.], v. 145, p. 110.210, 2025.

CHEN, K. et al. Predicting the Geopolymerization Process of Fly-Ash-Based Geopolymer Using Machine Learning. **Buildings**, [S.l.], 2022.

CHEN, S. et al. A Novel MBAS-RF Approach to Predict Mechanical Properties of Geopolymer-Based Compositions. **Gels**, [S.l.], 2023.

CHEN, Y.-C. et al. The Length Change Ratio of Ground Granulated Blast Furnace Slag-Based Geopolymer Blended with Magnesium Oxide Cured in Various Environments. **Polymers**, [S.l.], 2022.

CHOWDHURY, S. et al. Performance enhancement of commercial ethylene oxide reactor by artificial intelligence approach. **International Journal of Chemical Reactor Engineering**, [S.l.], v. 20, n. 2, p. 237-250, 2022.

CHU, H. H. et al. Sustainable use of fly-ash: use of gene-expression programming (GEP) and multi-expression programming (MEP) for forecasting the compressive strength geopolymer concrete. **Ain Shams Engineering Journal**, [S.l.], v. 12, p. 3.603-3.617, 2021.

CIOS, K. J. et al. **Data Mining: a Knowledge Discovery Approach**. Nova York: Springer, 2007.

COELHO, M. H. et al. Método para a Classificação de Áreas Queimadas Baseado em Aprendizado de Máquina Automatizado. In: COMPUTERS ON THE BEACH. v. 13, p. 29-36, 2022.

CORREA, D. M. Feature Engineering: preparando dados para aprendizado de máquina. **Ateliware**, [S.l.], mai. 2021. Disponível em: <https://ateliware.com/blog/feature-engineering>. Acesso em: 26 set. 2022.

COSENZA, D. N. E. A. Classificação da capacidade produtiva de sítios florestais utilizando máquina de vetor de suporte e rede neural artificial. **Scientia Forestalis**, [S.l.], v. 43, n. 108, p. 955-963, 2015.

COSTA, L. D. F.; CESAR JR., R. M. Shape Classification and Analysis. **CRC Press**, [S.l.], n. 2, 2018. (ISSN 9781315222325).

CRUZ, A. S. et al. Multi-objective optimization based on surrogate models for sustainable building design: A systematic literature review. **Building and Environment**, [S.l.], 2024.

DAO, D. V. et al. Artificial Intelligence Approaches for Prediction of Compressive Strength of Geopolymer Concrete. **Materials**, [S.l.], 2019.

DAO, D. V. et al. Prediction of Compressive Strength of Geopolymer Concrete Using Entirely Steel Slag Aggregates: Novel Hybrid Artificial Intelligence Approaches. **Applied Sciences**, Suíça, 2019.

DARMITON. Como representar uma tarefa de aprendizagem de máquina: handcrafted features vs feature learning. **Máquinas que Aprendem**, 2020. Disponível em: <https://maquinasqueaprendem.com/2020/03/24/como-representar-uma-tarefa-de-aprendizagem-de-maquina-handcrafted-features-vs-feature-learning/>. Acesso em: 18 nov. 2024.

DATTA, S. D. et al. Artificial intelligence and machine learning applications in the project lifecycle of the construction industry: A comprehensive review. **Heliyon**, [S.l.], 2024.

DAVIDOVITS, J. **Geopolymer: Chemistry & Applications**. Saint-Quentin. Geopolymer Institute, v. 3, 2020.

DEEPAK, M. et al. Crack width prediction of RC beams by artificial neural networks. **MaterialsToday: Proceedings**, [S.l.], 2023.

DONEDA, D. C. M. et al. Considerações iniciais sobre inteligência artificial, ética e autonomia pessoal. **Pensar-Revista de Ciências Jurídicas**, [S.l.], v. 23, n. 4, p. 1-17, 2018.

DOURI, H. et al. Enhanced dielectric properties of phosphoric acid-based geopolymers with different amounts of H₃PO₄. **Materials Letters**, [S.l.], p. 9-12, 2014.

DOURI, H. et al. Enhanced dielectric performance of metakaolin-H₃PO₄ geopolymers. **Materials Letters**, [S.l.], p. 299-302, 2016.

DU, X.; SALASAKAR, S.; THAKUR, G. A Comprehensive Summary of the Application of Machine Learning Techniques for CO₂-Enhanced Oil Recovery Projects. **Machine Learning and Knowledge Extraction**, [S.l.], v. 6, n. 2, p. 917-943, 2024.

DUXSON, P. et al. The role of inorganic polymer technology in the development of 'green concrete'. **Cement and Concrete Research**, [S.l.], v. 37, n. 12, p. 1.590-1.597, 2007.

EMARAH, D. A. Compressive strength analysis of fly ash-based geopolymer concrete using machine learning approaches. **Results in Materials**, [S.l.], dez. 2022.

ESPARHAM, A.; MEHRDADI, N. Effect of combined different sources of alumina silicate on mechanical properties and carbonation depth of environmentally friendly geopolymeric composite based on metakaolin. **International Journal of Engineering**, [S.l.], 2023.

EYRING, V. et al. Pushing the frontiers in climate modelling and analysis with machine learning. **Nature Climate Change**, [S.l.], v. 14, p. 916-928, 2024.

FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. D. S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. **Latin American Journal of Solids and Structures**, [S.l.], v. 16, n. 2, e165, 2019.

FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of eugenics**, [S.l.], v. 7, p. 179-188, 1936.

FLACH, P. **Machine Learning: the Art and Science of Algorithms that Make Sense of Data**. Nova York: Cambridge University Press, 2022.

FONTELLES, E. Como melhor tratar variáveis categóricas para modelos de machine learning — Parte 1. **Medium**, [S.l.], 2020. Disponível em: <https://medium.com/datarisk-io/como-melhor-tratar-vari%C3%A1veis-categ%C3%B3ricas-para-modelos-de-machine-learning-parte-1-a0e3a946bb1e>. Acesso em: 17 set. 2022.

FOURURE, D. et al. Anomaly Detection: how to Artificially Increase Your F1-Score with a Biased Evaluation Protocol. **Joint European Conference on Machine Learning and Knowledge Discovery in Databases**, p. 3-18, 2021.

FRÄNTI, P.; MARIESCU-ISTODOR, R. Soft precision and recall. **Pattern Recognition Letters**, [S.l.], v. 167, p. 115-121, 2023.

FU, G. et al. The role of deep learning in urban water management: a critical review. **Water Research**, [S.l.], v. 223, p. 118.973, 2022.

GARCIA, A. C. Ética e inteligência artificial. **Computação Brasil**, [S.l.], v. 43, p. 14-22, 2020.

GARCÍA, S. et al. Big data preprocessing: methods and prospects. **Big Data Analytics**, [S.l.], 2016.

GARCIA, S.; LUENGO, J.; HERRERA, F. **Data Preprocessing in Data Mining**. [S.l.]: Springer, 2015.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow**. 2. ed. [S.l.]: O'Reilly Media, Inc., 2019.

GNAT, S. Impact of Categorical Variables Encoding on Property Mass Valuation. **Procedia Computer Science**, Polônia, v. 192, 2021. P. 3542-3550. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877050921018664>. Acesso em: 16 set. 2022.

GOMAA, E. et al. Machine learning to predict properties of fresh and hardened alkali-activated concrete. **Cement and Concrete Composites**, [S.l.], jan. 2021.

GOOGLE AI. Data Preparation and Feature Engineering in ML, 2022. Disponível em: <https://developers.google.com/machine-learning/data-prep>. Acesso em: 22 set. 2022.

GOOGLE AI. Responsible AI practices, 2022. Disponível em: <https://ai.google/responsibilities/responsible-ai-practices/>. Acesso em: 22 set. 2022.

GOOGLE CLOUD. Qual é a diferença entre aprendizado profundo, machine learning e inteligência artificial? **Google Cloud**, 2024. Disponível em: <https://cloud.google.com/discover/deep-learning-vs-machine-learning>. Acesso em: 18 nov. 2024.

GRANDO, N. A Essência do Aprendizado de Máquina, mai. 2022. Disponível em: <https://neigrando.com/2022/05/04/a-essencia-do-aprendizado-de-maquina/>. Acesso em: 9 set. 2022.

GUNASEKARA, C. et al. Novel Analytical Method for Mix Design and Performance Prediction of High Calcium Fly Ash Geopolymer Concrete. **Polymers**, [S.l.], mar. 2021.

HAIR, J. F. et al. **Multivariate Data Analysis**. 7. ed. [S.l.]: Pearson, 2013.

HALKIDI, M.; BATISTAKIS, Y.; VAZIRGIANNIS, M. On Clustering Validation Techniques. **Journal of Intelligent Information Systems**, [S.l.], 107-145, dez. 2001.

HAMIE, H. et al. Application of non-parametric statistical methods to predict pumpability of geopolymers for well cementing. **Journal of Petroleum Science and Engineering**, [S.l.], p. 212, 2022.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J.. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2. ed. [S.l.]: Springer, 2009.

HOANG, N. D. et al. Estimating compressive strength of high-performance concrete with Gaussian process regression model. **Advances in Civil Engineering**, [S.l.], 2016.

HOAYEK, A. et al. Prediction of geopolymer pumpability and setting time for well zonal isolation- Using machine learning and statistical based models. **Heliyon**, [S.l.], 2023.

HONG, Y.; CHAN, D. W. M. Research trend of joint ventures in construction: a two-decade taxonomic review. **Journal of Facilities Management**, [S.l.], p. 118-141, 2014.

HOSSEINI, M. M.; PARVANIA, M. Artificial intelligence for resilience enhancement of power distribution systems. **The Electricity Journal**, p.106880, 2021. DOI: <https://doi.org/10.1016/j.tej.2020.106880>.

HUANG, D. et al. Ultra-Scalable Spectral Clustering and Ensemble Clustering. **IEEE Transactions on Knowledge and Data Engineering**, [S.l.], 2020.

HUYNH, A. T. et al. A Machine Learning-Assisted Numerical Predictor for Compressive Strength of Geopolymer Concrete Based on Experimental Data and Sensitivity Analysis. **Applied Sciences**, [S.l.], v. 21, 2020.

IBGE. Códigos dos municípios IBGE. **Instituto Brasileiro de Geografia e Estatística**, 2025. Disponível em: <https://www.ibge.gov.br/explica/codigos-dos-municipios.php>. Acesso em: 28 fev. 2025.

IBRAR, M. et al. A Machine Learning-Based Model for Stability Prediction of Decentralized Power Grid Linked with Renewable Energy Resources. **Wireless Communications and Mobile Computing**, [S.l.], n. 1, p. 2697303, 2022.

JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data clustering: a review. **ACM Computing Surveys**, [S.l.], p. 264-323, 1999.

JAMES, et al. **An Introduction to Statistical Learning with Applications in R**. 2. ed. [S.l.]: Springer, 2023.

JAMES, G. et al. **An Introduction to Statistical Learning**. 8. ed. [S.l.]: Springer, 2017.

JANOS, M. Validação de Modelos em Machine Learning. **3 dimensões – Matemática e Inteligência Artificial**, [S.l.], 2022. Disponível em: <https://www.3dimensoes.com.br/post/valida%C3%A7%C3%A3o-de-modelos-em-machine-learning>. Acesso em: 26 set. 2022.

JANSEN, M. et al. Engaging Citizen Scientists in Biodiversity Monitoring: Insights from WildLIVE! Project. **Citizen Science: Theory and Practice**, [S.l.], v. 9, n. 1, p. 6, 2024.

JAYARAMAN, P. et al. Critical review on water quality analysis using IoT and machine learning models. **International Journal of Information Management Data Insights**, [S.l.], v. 4, n. 1, p. 100.210, 2024.

JOSE, A. B.; DAS, P. A Multi-objective Approach for Inter-cluster and Intra-cluster Distance Analysis for Numeric Data. **Soft Computing: Theories and Applications**, [S.l.], p. 319-332, 2022.

JUDGE, M. A. et al. A comprehensive review of artificial intelligence approaches for smart grid integration and optimization. **Energy Conversion and Management: X**, [S.l.], 2024. DOI: <https://doi.org/10.1016/j.ecmx.2024.100724>.

KARALE, A. The challenges of IoT addressing security, ethics, privacy, and laws. **Internet of Things**, cidade, v. 15, p. 100420, 2021.

KHAN, K. et al. Assessment of Artificial Intelligence Strategies to Estimate the Strength of Geopolymer Composites and Influence of Input Parameters. **Polymers**, [S.l.], 2022.

KHAN, M. A. et al. Application of Gene Expression Programming (GEP) for the Prediction of Compressive Strength of Geopolymer Concrete. **Materials**, [S.l.], 2021.

KHAN, M. A. et al. Geopolymer Concrete Compressive Strength via Artificial Neural Network, Adaptive Neuro Fuzzy Interface System, and Gene Expression Programming With K-Fold Cross Validation. **Frontiers in Materials**, [S.l.], 2021.

KOHAVI, R. **A study of cross-validation and bootstraps for accuracy estimation and model selection**. In: International Joint Conference on Artificial Intelligence. Montreal, p.1.137-1.143, 1995.

KONG, Y. K.; KURUMISAWA, K. Application of machine learning in predicting workability for alkali-activated materials. **Case Studies in Construction Materials**, [S.l.], 2023.

KOSHIYAMA, A. et al. Towards algorithm auditing: a survey on managing legal, ethical and technological risks of AI, ML and associated algorithms. **SSRN**, [S.l.], 2021.

LEITE, R. Introdução a Validação-Cruzada: K-Fold. **Medium**, [S.l.], out. 2020. Disponível em: <https://drigols.medium.com/introdu%C3%A7%C3%A3o-a-valida%C3%A7%C3%A3o-cruzada-k-fold-2a6bcd32a90>. Acesso em: 26 set. 2022.

LEONG, H. Y. et al. Effects of Significant Variables on Compressive Strength of Soil-Fly Ash Geopolymer: Variable Analytical Approach Based on Neural Networks and Genetic Programming. **Journal of Materials in Civil Engineering**, [S.l.], 2018.

LI, L. et al. Recent advances in artificial intelligence and machine learning for nonlinear relationship analysis and process control in drinking water treatment: A review. **Chemical Engineering Journal**, [S.l.], v. 405, p. 126.673, 2021.

LI, L. et al. Surface Cracking and Fractal Characteristics of Bending Fractured Polypropylene Fiber-Reinforced Geopolymer Mortar. **Fractal and Fractional**, [S.l.], 2021.

LI, Y et. al. New revolution for quality control of TCM in industry 4.0: focus on artificial intelligence and bioinformatics. **TrAC Trends in Analytical Chemistry**, v. 181, p.118023, 2024. DOI: <https://doi.org/10.1016/j.trac.2024.118023>

LI, Z et al. Machine learning in concrete science: applications, challenges, and best practices. *npj Computational Materials*, v. 8, n. 127, 2022. DOI: <https://doi.org/10.1038/s41524-022-00810-x>

LIPPMANN, R. An introduction to comouting with neural nets. **IEEE ASSP Magazine**, [S.l.], p. 4-22, 1987.

LIU, J.; HEIN, J. E. Automation, analytics and artificial intelligence for chemical synthesis. **Nature Synthesis**, [S.l.], v. 2, n. 6, p. 464-466, 2023.

LIU, Q. et al. Artificial intelligence for production, operations and logistics management in modular construction industry: A systematic literature review. *Information Fusion*, v. 109, p. 102423, set. 2024. DOI: <https://doi.org/10.1016/j.inffus.2024.102423>

LOPES, C. M.; MENDES, J. C. Ética e inteligência artificial: desafios e melhores práticas. *Revista da UFMG*, v. 30, n. fluxo contínuo, 2023. Disponível em: <https://periodicos.ufmg.br/index.php/revistadaufmg/article/view/47673> . Acesso em: 30 abr. 2023.

LOUATI, S.; BAKLOUTI, S.; SAMET, B. Acid based geopolymerization kinetics: effect of clay particle size. **Applied Clay Science**, [S.l.], p. 571-578, 2016.

LOUATI, S.; BAKLOUTI, S.; SAMET, B. Geopolymers based on phosphoric acid and illito-kaolinitic clay. **Advances in Materials Science Engineering**, [S.l.], 2016.

LU, S. et al. Exploring the comprehensive integration of artificial intelligence in optimizing HVAC system operations: a review and future Outlook. **Results in Engineering**, v. 25, p. 103765, 2025. DOI: <https://doi.org/10.1016/j.rineng.2024.103765>.

MACHADO, D. F. M. et al. Avaliação de algoritmos de aprendizado de máquina na previsão de evasão escolar: estudo de caso no IFPA campus Altamira. **Cuadernos de Educación y Desarrollo**, [S.l.], v. 16, n. 10, p. e5874, 2024. DOI: <https://doi.org/10.55905/cuadv16n10-067>.

MAHAMAT, A. A. et al. Machine Learning Approaches for Prediction of the Compressive Strength of Alkali Activated Termite Mound Soil. **Applied Sciences**, [S.l.], 2021.

MAHESH, B. Machine Learning Algorithms- A Review. **International Journal of Science and Research**, [S.l.], 2018.

MANSOURI, E.; MANFREDI, M.; HU, J.-W. Environmentally Friendly Concrete Compressive Strength Prediction Using Hybrid Machine Learning. **Sustainability**, Suíça, out. 2022.

MARUKATAT, S. Tutorial on PCA and approximate PCA and approximate kernel PCA. **Artificial Intelligence Review**, [S.l.], v. 56, p. 5.445-5.477, 2022.

MATHIVET, V. et al. Acid-based geopolymers: understanding of the structural evolutions during consolidation and after thermal treatments. **Journal of Non-Crystalline Solids**, [S.l.], v. 512, p. 90-97, 2019.

MEHO, L. I.; ROGERS, Y. Citation counting, citation ranking, and h-index of human-computer interaction researchers: A comparison of Scopus and Web of Science. **Journal of the American Society for Information Science and Technology**, [S.l.], p. 1.711-1.726, 2008.

MITTELSTADT, B. D. et al. The ethics of algorithms: mapping the debate. **Big Data & Society**, [S.l.], v. 3, n. 2, p. 1-21, 2016.

MÖBIUS. An Overview of Categorical Encoding Methods. **Kaggle**, [S.l.], 2021. Disponível em: <https://www.kaggle.com/code/arashnic/an-overview-of-categorical-encoding-methods/notebook>. Acesso em: 16 set. 2022.

MOEIN, M. M. et al. Predictive models for concrete properties using machine learning and deep learning approaches: A review. **Journal of Building Engineering**, v. 63, p.105444, 2023. DOI: <https://doi.org/10.1016/j.jobbe.2022.105444>

MOEINI, B. et al. Surface analysis insight note. Principal component analysis (PCA) of an X-ray photoelectron spectroscopy image. The importance of preprocessing. **Surface and Interface Analysis**, [S.l.], v. 55, n. 11, p. 798-807, 2023.

MOHD, T.; MASROM, S.; JOHARI, N. Machine learning housing price in petaling jaya, Selangor, Malaysia. **International Journal of Recent Technology and Engineering (IJRTE)**, [S.l.], p. 542-546, 2019.

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of Machine Learning**. [S.l.]: MIT Press, 2018.

MURAINA, I. Ideal dataset splitting ratios in machine learning algorithms: general concerns for data scientists and data analysts. In: 7th INTERNATIONAL MARDIN ARTUKLU SCIENTIFIC RESEARCH CONFERENCE. [S.l.], p. 496-504, 2022.

MURPHY, K. P. **Machine Learning: a Probabilistic Perspective**. Londres: Massachusetts Institute of Technology, 2012.

NAGARAJU, T. V. et al. Geopolymer-stabilized soils: influencing factors, strength development mechanism and sustainability. **Journal of Taibah University for Science**, [S.l.], 2023.

NAZAR, S. et al. Machine learning interpretable-prediction models to evaluate the slump and strength of fly ash-based geopolymer. **Journal of Materials Research and Technology**, [S.l.], p. 100-124, 2023.

NEOWAY. **O que é data leakage e como essa falha pode contaminar as decisões**, [S.l.], 2022. Disponível em: <https://blog.neoway.com.br/data-leakage/>. Acesso em: 26 set. 2022.

NEX SOFTSYS SOFTWARE DEVELOPMENT COMPANY. **Common Pitfalls Which May Mislead Results In Machine Learning**, 2022. Disponível em: <https://www.nexsoftsys.com/articles/common-pitfalls-in-machine-learning.html>. Acesso em: 22 set. 2022.

NGO, A. Q.; NGUYEN, L. Q.; TRAN, V. Q. Developing interpretable machine learning-shapley additive explanations model for unconfined compressive strength of cohesive soils stabilized. **PLoS ONE**, [S.l.], 2023.

NI, H.-G.; WANG, J.-Z. Prediction of compressive strength of concrete by neural networks. **Cement and Concrete Research**, v. 30, n. 8, p. 1245-1250, 2000. DOI: [https://doi.org/10.1016/S0008-8846\(00\)00345-8](https://doi.org/10.1016/S0008-8846(00)00345-8).

OBERMEYER, Z. et al. Dissecting racial bias in an algorithm used to manage the health of populations. **Science**, [S.l.], v. 366, n. 6.464, p. 447-453, 2019.

OBREZANOVA, O. Artificial intelligence for compound pharmacokinetics prediction. **Current Opinion in Structural Biology**, [S.l.], v. 79, p. 102-546, 2023.

PAIXÃO, R. C. F. D. et al. Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization. **IBRACON Structures and Materials Journal**, [S.l.], v. 15, n. 5, p. 1-17, 2022.

PENG, Y.; UNLUER, C. Analyzing the mechanical performance of fly ash-based geopolymer concrete with different machine learning techniques. **Construction and Building Materials**, [S.l.], p. 316, 2022.

PENIDO, R. E. et al. Predicting the compressive strength of steelmaking slag concrete with machine learning- Considerations on developing a mix design tool. **Construction and Building Materials**, [S.l.], v. 341, p. 127-896, 2022.

PENIDO, R. E.-K. et al. Predicting the compressive strength of steelmaking slag concrete with machine learning – Considerations on developing a mix design tool. **Construction and Building Materials**, [S.l.], 2022.

PINTELAS, E. et al. A multi-view-CNN framework for deep representation learning in image classification. **Computer Vision and Image Understanding**, [S.l.], 2023.

PITA, R. P. **Aprendizado de Máquina e o Mercado Imobiliário**: estimativa do Preço de Venda de Imóveis Residenciais na Cidade de Juiz de Fora- MG. 2023. Dissertação (Mestrado)- Universidade Federal de Ouro Preto. Ouro Preto, 2023.

PRAKASH, A.; NAVYA, N.; NATARAJAN, J. Big Data Preprocessing for Modern World: Opportunities and Challenges. In: INTERNATIONAL CONFERENCE INTELLIGENT DATA COMMUNICATION TECHNOLOGIES AND INTERNET THINGS. [S.l.], 2018.

PRAMODITHA, R. 11 Dimensionality reduction techniques you should know in 2021. **Towards Data Science**, [S.l.], 2021. Disponível em: <https://towardsdatascience.com/11-dimensionality-reduction-techniques-you-should-know-in-2021-dcb9500d388b>. Acesso em: 19 nov. 2024.

PUTTEGOWDA, M.; NAGARAJU, S. B. Artificial intelligence and machine learning in mechanical engineering: Current trends and future prospects. **Engineering Applications of Artificial Intelligence**, [S.l.], 2025. DOI: <https://doi.org/10.1016/j.engappai.2024.109910>.

RAHMAN, A. et al. Advancements in Breast Cancer Diagnosis: Integrating Classifier Algorithms, Neural Network and Ensemble Learning with PCA, VIF for Feature Selection and Dimensionality Reduction. In: **International Conference on Electrical Engineering and Information & Communication Technology (ICEEICT)**, 6th, Dhaka, Bangladesh, 2024, pp. 893-898, DOI: 10.1109/ICEEICT62016.2024.10534427.

RAHMAN, S. K.; AL-AMERI, R. Structural assessment of Basalt FRP reinforced self-compacting geopolymer concrete using artificial neural network (ANN) modelling. **Construction and Building Materials**, [S.l.], 2023.

REZENDE, S. O. **Sistemas inteligentes**: fundamentos e aplicações. [S.l.]: Editora Manole Ltda., 2003.

RISTIC, N. et al. Gaussian Regression Process for Prediction of Compressive Strength of Thermally Activated Geopolymer Mortars. **Tehnički vjesnik**, [S.l.], p. 1.833-1.840, 2022.

ROSSETTI, R.; ANGELUCI, A. Ética Algorítmica: questões e desafios éticos do avanço tecnológico da sociedade da informação. **Galáxia**, [S.l.], v. 46, p. 1-18, 2021.

SACRAMENTO, G. Dataset: entenda o que é e conheça 10 fontes confiáveis. **Tera Blog**, [S.l.], 2021. Disponível em: <https://blog.somostera.com/data-science/dataset>. Acesso em: 20 nov. 2024.

- SÁEZ, J. A.; CORCHADO, E. ANCES: A novel method to repair attribute noise in classification problems. **Pattern Recognition**, [S.l.], 2022.
- SAGIROGLU, S.; SINANC, D. **Big data**: a review. 2013 international conference on collaboration technologies and systems. [S.l.]: IEEE, p.42-47, 2013.
- SALTELLI, A.; PUY, A.; FIORE, M. D. Mathematical models: a state of exception. **International Review of Applied Economics**, [S.l.], p. 1-18, 2024. (ISSN 10.1080/02692171.2024.2365727).
- SAMANTA, I. S. et al. Artificial intelligence and machine learning techniques for power quality event classification: a focused review and future insights. **Results in Engineering**, v. 25, p. 103873 mar. 2025. DOI: <https://doi.org/10.1016/j.rineng.2024.103873>
- SANTOS, M. S. et al. Cross-validation for imbalanced datasets: avoiding overoptimistic and overfitting approaches. **IEEE Computational Intelligence Magazine**, [S.l.], v. 13, n. 4, p. 59-76, 2018.
- SAVIETTO, J. V. Machine Learning: Métricas, Validação Cruzada, Bias e Variância. **Medium**, [S.l.], p. 21, 2021. Disponível em: <https://medium.com/@jvsavietto6/machine-learning-m%C3%A9tricas-valida%C3%A7%C3%A3o-cruzada-bias-e-vari%C3%A2ncia-380513d97c95>. Acesso em: 26 set. 2022.
- SCAIFE, A. D. Improve predictive maintenance through the application of artificial intelligence: A systematic review. **Results in Engineering**, v. 21, p. 101645, 2024. DOI: <https://doi.org/10.1016/j.rineng.2023.101645>.
- SHARMA, S. et al. Recurrent dictionary learning for state-space models with an application in stock forecasting. **Neurocomputing**, v. 450, p. 1-132021. DOI: <https://doi.org/10.1016/j.neucom.2021.03.111>.
- SHEIATI, S.; BEHBOODI, S.; RANJBAR, N. Segmentation of backscattered electron images of geopolymers using convolutional autoencoder networks. **Expert Systems with Applications**, [S.l.], 2022.
- SILVEIRA, M.; MARCOLIN, C. B.; FREITAS, H. M. R. D. **O Big Data e seu uso corporativo**: uma revisão da literatura. In: IV SINGEP. São Paulo, [s.n.], p. 1-16, 2015.
- SINGH, D.; SINGH, B. Investigating the impact of data normalization on classification performance. **Applied Soft Computing**, [S.l.], v. 97, p. 105-524, 2020.
- SOUZA, K. et al. Agricultura Digital Pesquisa, desenvolvimento e inovações nas cadeias produtivas. In: SOUZA, K. et al. **Agricultura Digital Pesquisa, desenvolvimento e inovações nas cadeias produtivas**. Brasília: EMPRAPA, 2020.

SPOHR, D. Fake news and ideological polarization: Filter bubbles and selective exposure on social media. **Business information review**, [S.l.], v. 34, p. 150-160, 2017.

STILGOE, J. Machine learning, social learning and the governance of self-driving cars. **Social Studies of Science**, [S.l.], v. 48, n. 1, p. 25-26, 2018.

SUNIGA, A. Conjuntos de treino, validação e teste em Machine Learning. **Medium**, [S.l.], 2020. Disponível em: <https://medium.com/@abnersuniga7/conjuntos-de-treino-teste-e-valida%C3%A7%C3%A3o-em-machine-learning-fast-ai-5da612dcb0ed>. Acesso em: 26 set. 2022.

SVIDELOC. Target Encoding vs. One-hot Encoding with Simple Examples. **Medium**, [S.l.], 2020. Disponível em: <https://medium.com/analytics-vidhya/target-encoding-vs-one-hot-encoding-with-simple-examples-276a7e7b3e64>. Acesso em: 16 set. 2022.

TANG, J. et al. Mechanical and microstructural properties of phosphate-based geopolymers with varying Si/Al molar ratios based on the sol-gel method. **Materials Letters**, [S.l.], p. 308, 2022.

TANG, Y. Z. et al. Artificial Neural Network-Forecasted Compression Strength of Alkaline-Activated Slag Concretes. **Sustainability**, Suíça, 2022.

TANYILDIZI, H. Predicting the geopolymerization process of fly ash-based geopolymer using deep long short-term memory and machine learning. **Cement and Concrete Composites**, [S.l.], 2021.

TARIQ, S.; HU, Z.; ZAYED, T. Micro-electromechanical systems-based technologies for leak detection and localization in water Supply networks: A bibliometric and systematic review. **Journal of Cleaner Production**, [S.l.], 2021.

TELES, T. **Linkedin**. Disponível em: <https://pt.linkedin.com/pulse/explorando-encoders-em-algoritmos-de-machine-learning-thiago-teles>. Acesso em: 18 jul. 2023.

TERRA, K. Codificando Variáveis Categóricas para Machine Learning | Mãos à obra Cientista de Dados #02. **Publicado pelo canal Programação Dinâmica**, [S.l.], 2021. Disponível em: <https://www.youtube.com/watch?v=ZPTAeXfaZ4g>. Acesso em: 24 ago. 2022.

TREVISAN, V. **Towards Data Science**, [S.l.], 2022. Disponível em: <https://towardsdatascience.com/dealing-with-categorical-variables-by-using-target-encoder-a0f1733a4c69>. Acesso em: ago. 2023.

UDDIN, M. F.; GUPTA, N. Seven V's of Big Data understanding Big Data to extract value. In: Proceedings of the 2014 zone 1- CONFERENCE OF THE AMERICAN SOCIETY FOR ENGINEERING EDUCATION. [S.l.]: IEEE, p. 1-5. 2014.

UNESCO. **Inteligência Artificial**: entre o mito e a realidade. [S.l.]: Correio da Unesco, v. 3, 2018.

UPRETI, K. et al. Prediction of Mechanical Strength by Using an Artificial Neural Network and Random Forest Algorithm. **Journal of Nanomaterials**, [S.l.], 2022.

VENKATASUBRAMANIAN, V.; MANN, V. Artificial intelligence in reaction prediction and chemical synthesis. **Current Opinion in Chemical Engineering**, [S.l.], v. 36, p. 100.749, 2022.

VILELA JR., G. B. et al. Métricas utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes. **Revista Centro de Pesquisas Avançadas em Qualidade de Vida**, [S.l.], v. 14, n. 2, p. 1-14, 2022.

VÖLKER, C. et al. Sequential learning to accelerate discovery of alkali-activated binders. **Journal of Materials Science**, [S.l.], p. 15.859-15.881, 2021.

WAGNER, N.; RONDINELLI, J. M. Theory-guided machine learning in materials science. **Frontiers in Materials**, [S.l.], v. 3, p. 28, 2016.

WANG, Q. et al. Application of Soft Computing Techniques to Predict the Strength of Geopolymer Composites. **Polymers**, [S.l.], 2022.

WANG, W. Dimensionality Reduction Task. In: WANG, W. **Principles of Machine Learning**. Singapore: Springer Nature, p. 481-595, 2024.

WINFIELD, A. F.; JIROTKA, M. Ethical governance is essential to building trust in robotics and artificial intelligence systems. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, [S.l.], v. 376, n. 2133, p. 20180085, 2018.

WUNI, I. Y.; SHEN, G. Q. P.; OSEI-KYEI, R. Scientometric review of global research trends on green buildings in construction journals from 1992 to 2018. **Energy and Buildings**, [S.l.], 69-85, 2019.

XU, D. et al. Concrete and steel bridge Structural Health Monitoring—Insight into choices for machine learning applications. **Construction and Building Materials**, [S.l.], 2023.

YADAV, D. **Towards Science**, [S.l.], 2019. Disponível em: <https://towardsdatascience.com/categorical-encoding-using-label-encoding-and-one-hot-encoder-911ef77fb5bd>. Acesso em: 7 ago. 2023.

YASEEN, Z. M. et al. Shear strength prediction of steel fiber reinforced concrete beam using hybrid intelligence models: a new approach. **Eng. Struct**, [S.l.], p. 244-255, 2018.

YILDIZ, B.; BILBAO, J.; SPROUL, A. A review and analysis of regression and machine learning models on commercial building electricity load forecasting. **Renewable and Sustainable Energy Reviews**, [S.l.], p. 1.104-1.122, 2017.

ZARUVNI, R. **Homem preto fica 10 dias preso por erro de reconhecimento facial**, dez. 2020. Disponível em: <https://www.tecmundo.com.br/software/208759-homem-preto-10-dias-presos-erro-reconhecimento-facial.htm>. Acesso em: 7 set. 2022.

ZEINI, H. A. et al. Random Forest Algorithm for the Strength Prediction of Geopolymer Stabilized Clayey Soil. **Sustainability**, Suíça, 2023.

ZHAO, Y. et al. Predicting compressive strength of manufactured-sand concrete using conventional and metaheuristic-tuned artificial neural network. **Measurement**, p. 110993, 2022. DOI: <https://doi.org/10.1016/j.measurement.2022.110993>

ZHU, X.; WU, X. Class Noise vs. Attribute Noise: a Quantitative Study. **Artificial Intelligence Review**, [S.l.], p. 177-210, 2004.

ZOU, Y. et al. Evaluation of Artificial Intelligence Methods to Estimate the Compressive Strength of Geopolymers. **Gels**, v. 8, n. 5, p. 271, 2022.

1.13 Sobre os(as) autores(as)

Aldo Ribeiro de Carvalho é professor no Instituto Federal do Sudeste de Minas Gerais (IF Sudeste MG), Campus Juiz de Fora, no núcleo de Construção Civil, e doutorando em Engenharia Civil na Universidade Federal de Ouro Preto (PROPEC/UFOP). Atualmente é membro do Ative-CNPq - Grupo de Pesquisas de Cimentos Álcali-Ativados e Ácidos-Ativados e do CIDENG-CNPq - Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia. Possui especializações em Docência no Ensino Superior, Engenharia de Segurança do Trabalho e em Gestão Pública em Defesa Civil. Tem experiências em patologias das construções, compósitos cimentícios, compósitos geopoliméricos ácidos e alcalinos, reaproveitamento de resíduos e aplicações de nanomateriais em materiais de construção.

Alexandre Abrahão Cury é graduado em Engenharia Civil pela UFJF (2006), mestre em Modelagem Computacional (2008) e doutor em Engenharia Civil pela École Nationale des Ponts et Chaussées (2010). Atua em monitoramento de integridade estrutural, detecção de danos, análise modal, machine learning

e confiabilidade estrutural. Professor associado no Departamento de Mecânica Aplicada e Computacional, foi coordenador do PEC/UFJF (2016-2019) e membro da CA-TEC/FAPEMIG. Recebeu menção honrosa no Prêmio CAPES de Tese 2017 e integra comitês do CNPq e da CAPES. É pesquisador de produtividade do CNPq e membro do corpo editorial da *Frontiers: Build Engineering, Structural Sensing, and Structural Engineering International*.

Anderson Ravik dos Santos é doutorando em Engenharia Civil pelo Programa de Pós-Graduação em Engenharia Civil (PROPEC) da Universidade Federal de Ouro Preto, tendo Materiais e Construção como área de concentração, com ênfase na produção de compósitos a partir da reciclagem de materiais poliméricos. Formado Técnico em Informática pelo Instituto Federal de Educação, Ciências e Tecnologia do Norte de Minas Gerais, Campus Salinas; Graduado Engenheiro Civil pela Universidade Federal de São João Del Rei, Campus Alto Paraopeba; e Mestre em Engenharia Civil, na área de concentração Materiais e Construção, pela Universidade Federal de Ouro Preto.

Carolina de Melo Nunes Lopes é engenheira civil pela Universidade Federal de Ouro Preto (2014). É mestre (2023) e doutoranda pela mesma instituição, no programa de pós-graduação em engenharia civil, área de concentração de materiais de construção. Atualmente é membro do CIDENG-CNPq, Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia. É especialista em Engenharia de Avaliações e Perícias pela PUC MG (2020). Atua em pesquisas relacionadas à materiais de construção sustentáveis, avaliação de ciclo de vida, aproveitamento de resíduos e inteligência artificial.

Danielle Rios Garcia é graduada e mestre em Engenharia Civil pela Universidade Federal de Juiz de Fora. Possui especializações em Sustentabilidade na Construção Civil, Qualidade e Marketing. Atualmente, é doutoranda em Engenharia Civil na Universidade Federal de Ouro Preto (PROPEC/UFOP), empreendedora e atua profissionalmente como consultora de negócios. Tem experiência em modelagem de negócios e planejamento estratégico, com foco na implementação de inovações para o aumento da produtividade empresarial. Sua pesquisa se concentra nessa área, envolvendo empreendedorismo e inovação na construção civil.

Júlia Castro Mendes é professora na Universidade Federal de Juiz de Fora (UFJF) e docente Permanente dos Programas de Pós-Graduação em Engenharia Civil da UFOP (PROPEC/UFOP) e da UFJF (PEC/UFJF). Coordenadora do CIDENG-CNPq - Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia. Representante brasileira da WREN - Women's Research Engineers Network. Tem experiência na área de aprendizagem de máquina aplicada à materiais de construção, materiais e técnicas de construção sustentáveis, reaproveitamento de resíduos sólidos, propriedades térmicas de matrizes cimentícias e eficiência energética em edificações.

Letícia Matias Martins é Engenheira Civil, Mestre em Engenharia Civil e doutoranda na Universidade Federal de Ouro Preto (UFOP/PROPEC). Durante sua formação acadêmica, adquiriu experiência prática em ensaios laboratoriais por meio de estágios no Laboratório de Materiais de Construção Civil da Univiçosa e na Andrade Couto Engenharia. Sua pesquisa atual foca no comportamento de argamassas de revestimento sob altas temperaturas, com ênfase na proteção passiva contra incêndios. Possui experiência em desempenho de materiais cimentícios sustentáveis, reaproveitamento de resíduos e propriedades térmicas de matrizes cimentícias.

Nalberth Vicentin Santana é Engenheiro Civil pela Universidade do Estado de Mato Grosso (UNEMAT), mestre e doutorando em Engenharia Civil na área de Estruturas e Construção pelo Programa de Pós-graduação em Engenharia Civil (PROPEC) da Universidade Federal de Ouro Preto (UFOP). Possui experiência em projetos de edificações em concreto armado, inspeção predial e otimização estrutural aplicada a elementos em aço fabricados em perfis formados a frio.

Nayara Mendes dos Santos é graduada em Engenharia Civil pela Faculdade Integrada de Cacoal (UNESC), especializado em Didática do Ensino Superior no Centro Universitário Maurício de Nassau de Cacoal e mestre em Engenharia Civil pelo Programa de Pós-Graduação em Engenharia Civil (PROPEC) da Universidade Federal de Ouro Preto, com ênfase em Materiais e Construção.

Rivelino Neri é engenheiro civil mestre e doutorando em Engenharia Civil pela Universidade Federal de Ouro Preto (UFOP). Sua pesquisa foca no desenvolvimento de materiais sustentáveis e duráveis, explorando rejeitos industriais em compósitos poliméricos para a produção de rochas ornamentais artificiais. Integra o grupo de pesquisa EcoUrb (UFOP) e o laboratório Intechlab (CEFET/MG). Com experiência em pesquisa científica, acessibilidade e análise de projetos, já publicou estudos sobre sustentabilidade na construção civil. Seu trabalho busca inovação e eficiência, aliando tecnologia e responsabilidade ambiental para criar soluções que minimizem impactos e ampliem a vida útil das construções.

Victor Higino Meneguitte Alves é engenheiro civil pela Universidade Federal de Juiz de Fora (UFJF), mestre e doutorando em Engenharia Civil na mesma instituição, com pesquisa focada no monitoramento da integridade estrutural por aprendizado de máquina. Atua como técnico de manutenção mecânica na Petrobras e como divulgador científico no grupo CIDENG-CNPq. Possui publicações em periódicos internacionais e capítulos de livros sobre inteligência artificial aplicada à engenharia estrutural. Sua pesquisa busca aprimorar a detecção e localização de danos em construções por meio da análise de dados vibracionais, explorando novas abordagens para diagnóstico e manutenção preditiva.

Vítor Freitas Mendes é graduado em Engenharia Civil, mestre e doutorando em Engenharia Civil com ênfase em Materiais de Construção pela UFOP. Tem experiência em simulação energética, modelagem computacional, análise de viabilidade, avaliação de impacto ambiental e desenvolvimento de tecnologias sustentáveis. Desenvolve pesquisas sobre otimização de edificações por meio de Inteligência Artificial. Busca inovações nas soluções para construções resilientes, aliando tecnologia, eficiência econômica e impacto ambiental reduzido. É professor assistente no IFMG - Campus Santa Luzia e membro do grupo CIDENG-CNPq.

2 PREDIÇÃO DO PREÇO DE IMÓVEIS POR MEIO DO APRENDIZADO DE MÁQUINA: UMA REVISÃO SISTEMÁTICA DA LITERATURA

Romário Parreira Pita¹, Aldo Ribeiro de Carvalho¹, Rafaela Miranda Barbosa², Alexandre Abrahão Cury², Julia Castro Mendes^{1,2}

¹ Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Ouro Preto.

² Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Juiz de Fora.

2.1 Resumo

Por meio de uma revisão bibliográfica de 63 artigos, este estudo investiga as principais tendências de pesquisa e as lacunas no uso de aprendizado de máquina (AM) para a precificação de imóveis. Os modelos mais utilizados foram Floresta Aleatória, Máquina de Reforço de Gradiente, XGBoost, Regressão Linear e Redes Neurais Artificiais. As principais fontes de dados para esses modelos foram *sites* imobiliários, que podem introduzir vieses relevantes. Entre as variáveis mais frequentemente adotadas estão “localização” na categoria locacional, “taxa de condomínio” na categoria financeira e “área do imóvel” na categoria física. Dentre as lacunas identificadas, destacam-se a falta de estudos sobre o impacto da variação temporal no valor de venda dos imóveis e a necessidade de um fator de correção que considere essa temporalidade, aprimorando assim as previsões futuras.

Palavras-Chave: Mercado Imobiliário, Avaliação de Imóveis, Precificação de Imóveis, Aprendizado de Máquina

2.2 Introdução

No mercado imobiliário, diferentemente das indústrias tradicionais de manufatura, não há um método padrão de precificação de produtos (Corrêa; Silva; Carvalho; Silva; Gonçalves, 2018). A análise de oferta e demanda, utilizada para bens convencionais, torna-se mais complexa nesse setor, dada a influência de variáveis como localização, acabamento, exposição ao sol e número de vagas, além de fatores subjetivos, que variam conforme as preferências dos(as) compradores(as). O mercado imobiliário é ainda impactado por políticas públicas, tributação, inflação, regulamentos de diferentes níveis governamentais e cenários internacionais (Lima Neto, 2015).

A diversidade dessas variáveis afeta significativamente os preços dos imóveis, sendo necessário o desenvolvimento de métodos eficazes de precificação que identifiquem os fatores mais relevantes. Esses métodos são essenciais para garantir negociações justas e estabelecer valores competitivos (Ebekozen; Abdul-Aziz; Jaafar, 2019; Zulkifley; Rahman; Ubaidullah; Ibrahim, 2020; Rico-Juan; de La Paz, 2021).

Nesse contexto, o aprendizado de máquina (AM), um ramo da inteligência artificial, surge como uma solução promissora. O AM compreende algoritmos capazes de identificar padrões autonomamente e realizar previsões ou classificações com base em dados, dispensando programação explícita (Mohri; Rostamizadeh; Talwalkar, 2018). A qualidade, representatividade e volume dos dados são fundamentais para o desempenho dos modelos de AM (Lopes; Mendes, 2023).

Este trabalho realiza uma revisão sistemática da literatura com o objetivo de investigar o uso de algoritmos de AM na previsão de preços de imóveis com a finalidade de identificar quais são as lacunas de conhecimento, a qualidade das técnicas mais frequentemente adotadas e as principais características inerentes a elas. Algumas revisões sobre o uso de AM na precificação de imóveis já foram até desenvolvidas, indicando resultados promissores (Zulkifley; Rahman; Ubaidullah; Ibrahim, 2020; Ja'afar; Mohamad; Ismail, 2021; Al-Qawasmi, 2022; Root; Strader; Huang, 2023). Entretanto, essas revisões focam predominantemente nas variáveis mais adotadas e nos algoritmos mais empregados, sem uma avaliação do desempenho desses algoritmos, dificultando a seleção para aplicação em estudos futuros. Além das técnicas mais empregadas, o presente trabalho buscou por tendências na qualidade dos modelos (especialmente em relação ao R^2) com base nos cenários, volume e tipo de dados dos artigos. Como resultado, identificamos lacunas de conhecimento que não foram abordadas em nenhum dos artigos de revisão anteriores.

2.3 Metodologia de Investigação

A coleta de dados foi realizada na base Scopus, a maior base global de resumos e citações de literatura revisada por pares (Scopus, 2022). Utilizou-se a string de busca: (“Machine Learning” OR “data mining”) AND (“Real Estate Market” OR “Property Valuation” OR “house price” OR “building value”). A última revisão ocorreu em 31 de agosto de 2023. Foram aplicados filtros para artigos publicados entre 2017 e 2023, em inglês e de acesso aberto. A busca resultou em 125 artigos, incluindo tanto artigos de periódicos quanto de conferências que foram publicados em periódicos. Não foram aplicados critérios de qualidade, como número de citações ou autoria, e a seleção por acesso aberto, apesar de uma limitação, visou democratizar o acesso aos trabalhos selecionados.

Em seguida, os títulos, resumos e palavras-chave foram avaliados, excluindo os artigos que não abordavam o uso de algoritmos de AM na precificação de imóveis residenciais. Ao final, 63 artigos foram selecionados para leitura integral e são apresentados no Apêndice A.

2.4 Resultados


2.4.1 Características das fontes e conjuntos de dados

Dos 63 estudos analisados, 22 utilizaram *sites* de vendas de imóveis (13 não especificaram quais); 19 consultaram diretórios públicos de transações imobiliárias; 6 coletaram dados em plataformas online de empresas do setor; 11 recorreram a repositórios de dados públicos usados em competições e estudos de ciência de dados e 5 não especificaram a fonte de dados. Dentre os estudos, 53% construíram seus próprios bancos de dados a partir de imóveis listados para venda, enquanto 47% utilizaram imóveis vendidos. Essa distinção é relevante, pois os preços de listagem tendem a diferir dos valores de transação, influenciando a precisão dos modelos preditivos. Além disso, a presença de anúncios falsos em plataformas online, como observado por Castelli (2020), pode distorcer os dados e comprometer a confiabilidade das previsões.

A falta de clareza sobre as fontes de dados e o processamento dos mesmos, mencionada por Caton e Haas (2023), dificulta a reprodutibilidade das pesquisas, essencial para validar os resultados e garantir a confiança na comunidade científica. Segundo Mehrabi et al. (2021), a transparência na coleta e processamento dos dados, bem como nos algoritmos, é fundamental para a interpretação e compreensão das decisões dos modelos.

Os estudos analisados adotaram de 89 a 12.223.582 instâncias, a Figura 1 apresenta essa quantidade de dados dos trabalhos e revela que a maioria utilizou 20.000 a 50.000 instâncias, sendo 7 a partir de anúncios, 6 de imóveis vendidos e 1 sem especificação.

Figura 1 – Quantidade de estudos em cada faixa de tamanho do banco de dados



Fonte: Autores.


Embora um maior volume de dados geralmente favoreça o desempenho dos algoritmos de aprendizado de máquina (Luca et al., 2022) apenas 6 artigos analisaram mais de 100.000 instâncias, e 7 trabalharam com menos de 1.000. No entanto, o desempenho dos modelos não depende apenas do volume de dados, mas também da representatividade das amostras, da presença de *outliers* e da capacidade do algoritmo de lidar com a complexidade dos dados (Sutton; Barto, 2018)

Dos estudos revisados, 7 utilizaram dados nacionais, 5 em nível estadual e 51 em nível municipal. A abrangência geográfica dos dados é um fator importante, uma vez que bases multiáreas desequilibradas podem afetar o desempenho do modelo, assim como a variabilidade dos atributos em diferentes contextos, como apontado por Bishop (2006).

2.4.2 Principais características adotadas

Nos artigos revisados, foram identificadas 26 características relevantes na avaliação dos preços de imóveis residenciais, categorizadas em três grupos: locacionais, financeiras e físicas, conforme apresentado na Figura 2.

Figura 2 – Principais parâmetros / variáveis de entrada dos trabalhos revisados



Fonte: Autores.

A categoria “Locacional” inclui aspectos relacionados ao endereço e ao bairro do imóvel, considerados por alguns autores como os mais significativos na determinação de preços (Gao et al., 2019; Rahadi et al., 2016; Alfiyatin et al., 2017). A localização é fundamental, pois áreas com melhor infraestrutura, tráfego e segurança tendem a ter preços mais elevados (Grybauskas et al., 2021). As metodologias para avaliação locacional variam entre estudos, incluindo o uso de endereços completos, coordenadas geográficas, CEP ou distância do centro da cidade. Essa diversidade metodológica carece de comparações sistemáticas sobre a eficácia de cada abordagem, o que é recomendado para trabalhos futuros. Notavelmente, características como a vista do imóvel e a orientação solar são pouco abordadas na literatura.

A categoria “Financeira” abrange despesas relacionadas à aquisição, uso e manutenção do imóvel, como impostos, taxas de condomínio e preço médio por metro quadrado. Essas características não foram citadas com a mesma frequência que as locacionais e físicas.


Por fim, a categoria “Física” engloba atributos que construtoras e incorporadoras utilizam para atrair compradores(as), como área útil, número de quartos e número de vagas de estacionamento. Owusu-Manu et al. (2019) destacam que características físicas têm impacto significativo nos preços, assim como as locacionais. O trabalho de Zhou (2020) apontou que os principais fatores influentes são o tamanho do imóvel, o número total de banheiros e a qualidade dos materiais. Adicionalmente, Owusu-Manu et al. (2019) observam que a adição de um andar, um quarto ou um banheiro pode aumentar o valor do imóvel em 13%, 16% e 2%, respectivamente.

Os modelos de AM aplicados à precificação de imóveis incorporam atributos quantitativos (variáveis numéricas, como área, número de quartos e CEP) e qualitativos (variáveis categóricas/nominais, como padrão de acabamento, tipo de vaga e bairro). No entanto, nenhum algoritmo de AM lida diretamente com variáveis categóricas, que precisam ser convertidas em números por meio de um processo conhecido como “codificação”. Alguns autores abordaram a codificação de variáveis categóricas usando tratamento binário, enquanto outros não especificaram suas técnicas. Não foram encontrados estudos comparativos sobre as diferentes estratégias de codificação e seu impacto na precisão dos modelos.

2.4.3 Algoritmos de aprendizado de máquina mais utilizados

A Figura 3 apresenta os algoritmos de AM mais utilizados nos 63 trabalhos que alcançaram uma frequência mínima de 3 menções. Os 11 modelos mais adotados foram: Floresta Aleatória (FA), MRG (Máquina de Reforço de Gradiente) + XGBoost (*Extreme Gradient Boost*), RL (Regressão Linear), RNA (Redes Neurais Artificiais), RVS (Regressão por Vetores de Suporte), AD (Regressor de Árvore de Decisão), KVMP (K Vizinhos Mais Próximos), RIDGE (também chamada Regressão de Cume), AdaBoost (Aumento Adaptativo), LASSO (Operador de Seleção e Redução Mínima Absoluta) e RA (Regressão Aumentada). Esses algoritmos podem ser agrupados em: 1) modelos baseados em árvore de decisão, como FA, XGBoost, RVS, AD, AdaBoost e RA; 2) algoritmos de regressão linear, incluindo RL, RIDGE e LASSO; e 3) outros métodos, como RNA, RVS e KVMP.

Figura 3 – Algoritmos mais utilizados



Fonte: Autores.

O MRG se destaca por sua alta performance, consistência e interpretabilidade, produzindo modelos preditivos a partir de árvores de decisão (Zhou, 2020; Ho; Tang; Wong, 2020). O XGBoost, uma evolução do MRG, inclui regularização para evitar *overfitting* e otimização para processamento paralelo, tornando-o mais eficiente em conjuntos de dados grandes e robustos em cenários reais (Chen; Guestrin, 2016; Zhou, 2020). Portanto, nesta pesquisa, MRG e XGBoost foram agrupados na mesma categoria. A FA é um outro algoritmo supervisionado que combina várias árvores de regressão para realizar previsões mais precisas (Silva, 2019). Cada árvore vota em um valor representativo e o resultado final é o valor mais votado (Afonso; Melo; Oliveira; Samuel; Berton, 2019).

A RL analisa dados para determinar relações entre variáveis dependentes e independentes, resultando em uma equação que representa essa relação. No entanto, a RL é sensível a erros aleatórios e não captura bem comportamentos não-lineares (García-Magariño; Medrano; Delgado, 2020). Modelos de regressão múltipla ajudam a identificar quais características do imóvel são mais relevantes para explicar a variável dependente (Zulkifley; Rahman; Ubaidullah; Ibrahim, 2020).

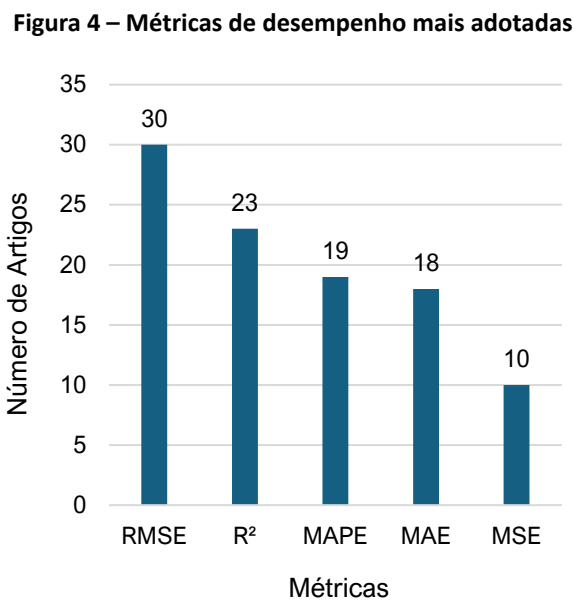
O modelo RNA capta relações não-lineares entre dados de entrada e saída, mostrando eficácia na estimativa de preços de imóveis residenciais (Zulkifley; Rahman; Ubaidullah; Ibrahim, 2020). Inspirado no cérebro humano, o RNA consiste em camadas de neurônios que ajustam pesos por meio de retropropagação.

As Máquinas de Vetores de Suporte (MVS), inicialmente desenvolvidas para categorização de padrões, foram expandidas para previsão de valores numéricos (regressão) como RVS. As RVSs buscam encontrar uma função que melhor prediz valores contínuos, maximizando a margem de tolerância ao erro em torno de uma linha de regressão ideal (Acosta; Amoroso; Santanna, 2016).

Os dados coletados indicam que os autores frequentemente adotam e comparam múltiplos algoritmos de AM, uma vez que cada um pode se adaptar de maneira diferente às características dos conjuntos de dados. Como cada grupo de pesquisa compara um conjunto diferente de algoritmos e como cada banco de dados tem características particulares, é difícil estabelecer um *ranking* definitivo das melhores técnicas de AM. Para tentar identificar padrões predominantes, os autores realizaram uma avaliação dos diferentes algoritmos com suas métricas de qualidade, como será visto na seção a seguir.

2.4.4 Métricas de qualidade dos modelos de aprendizado de máquina

A escolha de um algoritmo específico não garante, por si só, uma boa qualidade preditiva, a qual deve ser avaliada por meio de diversas métricas. A Figura 4 apresenta as métricas mais frequentemente utilizadas nos estudos revisados, considerando uma frequência mínima de 3. As mais comuns foram o Erro Quadrático Médio (RMSE), o Coeficiente de Determinação (R^2) e o Erro Percentual Absoluto Médio (MAPE), seguidos pelo Erro Absoluto Médio (MAE) e o Erro Quadrático Médio (MSE), explicados na seção 3.9.2.



Fonte: Autores.

A Tabela 1 apresenta a distribuição dos valores de R^2 obtidos para cada algoritmo em cada um dos estudos que adotaram essa métrica para avaliar a previsão de preços.

Tabela 1 - R² obtido em cada estudo segundo os algoritmos que foram adotados

Algoritmo Citação	ADB	AD	CTB	CAR	C	CL	FA	KVMP	L	LL	MRG	MPH	PG	RE	RL	RML	RNA	RVS	XGB
	(Oladunni, Sharma, & Tiwang, 2017)	-	-	-	-	-	-	0,800	-	-	-	-	-	-	-	-	-	-	-
(Baldominos A. , et al., 2018)	-	-	-	0,125	-	-	-	0,36	-	-	-	-	-	-	-	-	-	0,066	-
(Masrom, Mohd, Jamil, Rahman, & Baharun, 2019)	-	0,986	-	-	0,683	-	0,991	-	0,683	-	-	-	0,995	-	0,683	-	-	-	-
(Mohd, Masrom, & Johari, 2019)	-	0,986	-	-	0,683	-	0,991	-	0,683	-	-	-	-	-	0,683	-	-	-	-
(Almaslukh, 2020)	-	0,910	-	-	-	-	0,970	-	0,960	-	0,985	-	-	-	-	-	-	0,834	0,980
(Kuvalekar <i>et al.</i> , 2020)	-	0,890	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
(Castelli, Dobрева, Henriques, & Vanneschi, 2020)	-	-	-	-	0,194	-	0,363	0,239	0,183	-	-	-	-	-	-	-	-	0,076	-
(Al-Sit & Al-Hamad, 2020)	-	-	-	-	-	-	0,820	-	-	-	0,820	-	-	-	0,710	-	-	0,770	-
(Mrsic, Jerkovic, & Balkovic, 2020)	0,820	0,650	-	-	-	-	-	0,650	-	-	0,830	-	-	-	0,720	-	-	-	0,830
(Chiramel, Logofatu, Rawat, & Andersson, 2020)	-	-	-	-	0,886	-	-	-	-	-	-	-	-	-	0,888	-	-	-	-
(Rico-Juan e de La Paz, 2021)	0,667	0,747	0,935	-	-	0,823	0,986	0,928	-	0,423	-	-	-	-	0,823	-	-	-	0,897
(Ho, Tang, & Wong, 2020)	-	-	-	-	-	-	0,903	-	-	-	0,904	-	-	-	-	-	-	0,827	-
(Li, Jiang, Ke, Nie, & Wu, 2021)	-	-	-	-	-	-	-	-	-	-	-	0,600	-	-	-	-	-	-	0,944
(Kang, et al., 2020)	-	-	-	-	-	-	-	-	-	-	0,740	-	-	-	-	0,480	-	-	-
(Choy & Ho, 2023)	-	-	-	-	-	-	0,919	0,895	-	-	-	-	-	-	-	-	-	-	-
(Abdul-Rahman, Mutalib, & Zulkifley, 2021)	-	-	-	-	0,855	-	-	-	-	-	-	-	-	-	-	0,871	-	-	0,912
(Gao, Shi, Pettit, & Han, 2022)	-	0,771	-	-	0,699	-	0,868	-	0,419	-	0,867	-	-	-	-	-	-	0,439	0,59
(Mora-Garcia, Céspedes-Lopez, & Perez-Sanchez, 2022)	-	-	-	-	-	-	0,997	-	-	-	0,993	-	-	-	0,805	-	-	-	0,988
(Hjort, Pensar, Scheel, & Sommervoll, 2022)	-	-	-	-	-	-	0,904	0,734	-	-	-	-	-	-	0,730	-	-	-	0,914
(Zaki, Nayyar, Dalal, & H. Ali, 2022)	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,841
(Yağmur, Kayakuş, & Terzioğlu, 2022)	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,721	-	0,749	-
(Singh, Singh, Yadav, & Kumar, 2022)	-	-	-	-	-	-	0,901	-	-	-	0,650	-	-	-	-	0,549	-	0,580	-
(Teoh & Yau, 2022)	-	-	-	-	-	-	0,860	-	-	-	-	-	-	-	0,840	-	-	-	-

Fonte: Autores.

ADB – Adaboost | AD – Árvore de Decisão | CTB – Catboost | CAR – Conjuntos de Árvores de Regressão | C – Crista | FA – Floresta Aleatória | CL – Crista Linear | KVMP – K-Vizinhos Mais Próximos | L – Lasso | LL – Lasso Linear | MRG – Máquina de Reforço de Gradiente | MPH – Modelagem de Preço Hedônico | PG – Programação Genética | RE - Rede Elástica | RL – Regressão Linear | RML – Regressão Multi Linear | RNA – Redes Neurais Artificiais | RVS – Regressão de Vetor de Suporte | XGB – XGBoost

A ausência de uma tendência clara no comportamento dos algoritmos indica que diversos fatores, além do próprio algoritmo, influenciam o desempenho dos modelos de aprendizado de máquina. A qualidade dos dados é tão importante quanto sua quantidade, sendo que muitos *outliers* podem afetar significativamente a precisão das previsões. Bases de dados com alta similaridade entre instâncias apresentam menor precisão em comparação àquelas com maior variabilidade nos atributos, pois esta última permite um aprendizado mais amplo. Além disso, bases de dados desbalanceadas, com categorias desigualmente representadas, também comprometem o desempenho do modelo.

Para melhorar a qualidade dos dados, podem ser aplicadas técnicas de pré-processamento, como remoção de *outliers*, escalonamento, normalização, ajuste do volume de observações e preenchimento de valores ausentes. No entanto, observou-se que os autores raramente detalham esses tratamentos, dificultando a análise da relação entre métricas obtidas e características dos dados. Portanto, com base nas informações disponíveis, não é possível determinar quais algoritmos apresentam melhor desempenho para prever o valor de venda de propriedades.

Em termos de resultados numéricos, o maior R^2 (0,997) foi alcançado por Mora-Garcia et al. (2022), utilizando o algoritmo AF em um estudo com 39.943 instâncias e 27 atributos, coletados em Alicante, Espanha. Em contrapartida, Almaslakh (2020) obteve um R^2 de 0,985 com o algoritmo MRG em 414 instâncias e 5 atributos. Já o estudo de Ho, Tang e Wong (2020) utilizaram MRG em 39.554 instâncias, resultando em um R^2 de 0,904. Esses resultados indicam que a qualidade do modelo não está diretamente relacionada ao volume de dados e que não é simples identificar o melhor algoritmo de aprendizado de máquina.

2.5 Considerações Finais

Este trabalho realizou uma revisão sistemática da literatura envolvendo 63 artigos de acesso aberto que utilizam aprendizado de máquina (AM) na precificação de imóveis. O tamanho dos conjuntos de dados variou de 89 a 12.223.582 instâncias, com maior frequência entre 20.000 e 50.000 amostras (14 estudos, 22% do total). As fontes de dados incluíram sites de vendas (34%), diretórios de agências públicas (31%) e repositórios de dados (17%).

Foram identificados 26 atributos de entrada para prever o preço de venda, relacionados à localização, infraestrutura e despesas financeiras. Alguns autores investigaram a influência dos atributos, mas apresentaram resultados díspares.

As técnicas de AM mais adotadas foram Floresta Aleatória (FA), Aumento Extremo de Gradiente (XGBoost) + Máquina de Reforço de Gradiente (MRG), Redes

Neurais Artificiais (RNA), Regressão Linear (RL) e Regressão por Vetores de Suporte (RVS). As métricas utilizadas para avaliar a qualidade do modelo foram Erro Quadrático Médio (RMSE), Coeficiente de Determinação (R^2), Erro Percentual Absoluto Médio (MAPE), Erro Absoluto Médio (MAE) e Erro Quadrático Médio (MSE). Entre 11 autores que compararam múltiplos algoritmos, 7 relataram que o FA apresentou as melhores métricas.

Algumas lacunas de literatura observadas:

- Não foram encontrados estudos sobre a relação entre o tempo e entre listagem e venda e o preço.
- A maioria dos artigos não discutiu a aplicação de um índice de correção para atualizar preços, o que garantiria a atualidade dos dados de treinamento.
- Ajustes de valores considerando temporalidade, sazonalidade, oscilações de mercado e inflação foram raramente abordados.
- As estratégias de codificação para variáveis categóricas não foram suficientemente exploradas. Os poucos estudos, que aplicaram codificação, focaram em uma única técnica, utilizando tratamentos binários ou mencionando transformações sem especificar os processos.
- Em geral, houve falta de clareza nas metodologias, incluindo processamento de dados, critérios de coleta, tratamento de variáveis não numéricas e construção de modelos, dificultando a reprodutibilidade e a interpretação das decisões. Essa falta de clareza pode comprometer a confiabilidade dos modelos desenvolvidos.

Em conclusão, as técnicas de AM estudadas mostraram-se adequadas para prever preços de imóveis, desde que alimentadas por bases de dados representativas e avaliadas com métricas relevantes. Não foi encontrada uma técnica superior, pois o desempenho depende das características dos dados. Recomenda-se a experimentação de diversas técnicas, avaliadas por variadas métricas, para aprimorar a confiabilidade e precisão dos resultados no mercado imobiliário.

2.6 Agradecimentos

Agradecemos à UFOP (Universidade Federal de Ouro Preto) e à UFJF (Universidade Federal de Juiz de Fora) pela estrutura de laboratório e recursos materiais. Gostaríamos de expressar nossa gratidão às instituições que ofereceram apoio financeiro para este trabalho: FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais); CAPES (Coordenação de Aperfeiçoamento de Pessoal de

Nível Superior), pela bolsa de doutorado concedida a Aldo Ribeiro de Carvalho, código de financiamento 001; CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico, bolsa 305818/2023-6 - Pesquisadora PQ - para Julia Castro Mendes). Por fim, agradecemos ao grupo de pesquisa CIDENG-CNPq pelo apoio e colaboração.

2.7 Referências

ABDUL-RAHMAN, S.; MUTALIB, S.; ZULKIFLEY, N. Advanced Machine Learning Algorithms for House Price Prediction: Case Study in Kuala Lumpur. **International Journal of Advanced Computer Science and Applications**, [S.l.], p. 736-745, 2021.

ACOSTA, S.; AMOROSO, A.; SANTANNA, A. Modelagem de um Processo Produtivo Utilizando Regressão por Vetores Suporte. In: XXXVI ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, [S.l.], p. 15, 2016.

ADERIBIGBE, T.; CHI, H. Investigation of Florida Housing Prices using Predictive Time. **Pearc'18: Practice and Experience in Advanced Research Computing**. Pitisburgo: Association for Computing Machinery, p. 1-4, 2018. DOI: <https://doi.org/10.1145/3219104.3229253>.

AFONSO, B, et al. Housing Prices Prediction with a Deep Learning and Random Forest Ensemble. In: ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL E COMPUTACIONAL (ENIAC), Porto Alegre: Sociedade Brasileira de Computação, 2019.

AHTESHAM, M.; BAWANY, N. Z.; FATIMA, K. House Price Prediction using Machine Learning Algorithm- The Case of Karachi City, Pakistan. In: 21st INTERNATIONAL ARAB CONFERENCE ON INFORMATION TECHNOLOGY. Giza: IEEE, p. 1-5, 2020.

ALMASLUKH, B. A Gradient Boosting Method for Effective Prediction of Housing Prices in Complex Real Estate Systems. In: INTERNATIONAL CONFERENCE ON TECHNOLOGIES AND APPLICATIONS OF ARTIFICIAL INTELLIGENCE (TAAI). Taiwan: IEEE, p. 217-222, 2020. DOI: <https://doi.org/10.1109/TAAI51410.2020.00047>.

AL-QAWASMI, J. Machine Learning Applications in Real Estate: Critical Review of Recent Development. **Artificial Intelligence Applications and Innovations**. [S.l.]: Springer Nature Link, p. 231-249, 2022.

AL-SIT, W. T.; AL-HAMADIN, R. Real Estate Market Data Analysis and Prediction Based on Minor Advertisements Data and Locations' Geo-codes. **International Journal of Advanced Trends in Computer Science and Engineering**, [S.l.], p. 4.077-4.089, 2020.

BALDOMINOS, A. et al. Identifying Real Estate Opportunities Using Machine Learning. *Applied Sciences*, [S.l.], v. 8, n. 11, p. 1-24, 2018. DOI: <https://doi.org/10.3390/app8112321>.

BISHOP, C. M. *Pattern Recognition and Machine Learning*. [S.l.]: Springer, 2006.

CASTELLI, M. et al. Predicting Days on Market to Optimize Real Estate Sales Strategy. **Complexity**, p. 4603190, 2020. DOI: <https://doi.org/10.1155/2020/4603190>.

CATON, S; HAAS, C. Fairness in Machine Learning: a Survey. **ACM Computing Surveys**, [S.l.], 2023.

CHABASIT, K. et al. A Real Estate Valuation Model Using Boosted Feature Selection. *IEEE Access*, [S.l.], v. 9, p. 86938-86953, 2021. DOI: <https://doi.org/10.1109/ACCESS.2021.3089198>.

CHEN, T.; GUESTRIN, C. XGBoost: a Scalable Tree Boosting System. **Association for Computing Machinery**, [S.l.], 2016.

CHIRAMEL, S. et al. **Efficient Approaches for House Pricing Prediction by Using Hybrid Machine Learning Algorithms**. Phuket: Springer, 2020.

CHOU, J.-S.; FLESHMAN, D.-B.; TRUONG, D.-N. Comparison of machine learning models to provide preliminary forecasts of real estate prices. **Journal of Housing and the Built Environment**, [S.l.], p. 2.079-2.114, 2022.

CHOY, L.; HO, W. The Use of Machine Learning in Real Estate Research. *Land*, Basel, v. 12, p. 740, 2023.

ÇILGIN, C.; GÖKÇEN, H. Machine learning methods for prediction real estate sales prices in Turkey. **Revista de la Construcción. Journal of Construction**, Santiago, v. 22, n. 1, p. 163-177, 2023. DOI: <https://doi.org/10.7764/RDLC.22.1.163>.

CORRÊA, R. O. et al. A Influência do Conhecimento e da Atitude no Comportamento de Investidor do Mercado Imobiliário. **Revista de Administração FACES Journal**, v. 16, n. 4, p. 85-103, 2018.

DIMOPOULOS, T.; BAKAS, N. Artificial intelligence for mass appraisals of residential properties in Nicosia: mathematical modelling and algorithmic implementation. In: SEVENTH INTERNATIONAL CONFERENCE ON REMOTE SENSING AND GEOINFORMATION OF THE ENVIRONMENT. Paphos: SPIE, 2019.

DIMOPOULOS, T.; BAKAS, N. Sensitivity Analysis of Machine Learning Models for the Mass Appraisal of Real Estate. Case Study of Residential Units in Nicosia, Cyprus. **Remote Sensing**, [S.l.], 2019.

EBEKOZIEN, A.; ABDUL-AZIZ, A.-R.; JAAFAR, M. Housing finance inaccessibility for low-income earners in Malaysia: factors and solutions. **Habitat**, [S.l.], v. 8, 2019.

GAO, Q. et al. Property valuation using machine learning algorithms on statistical areas in Greater Sydney, Australia. *Land Use Policy*, [S.l.], 123, 2022.

GARCÍA-MAGARIÑO, Iván; MEDRANO, Carlos; DELGADO, Jorge. Estimation of missing prices in real-estate market agent-based simulations with machine learning and dimensionality reduction methods. **Neural Computing and Applications**, v. 32, n. 7, p. 2665-2682, 2020.

GHOSALKAR, N. N.; DHAGE, S. N. Real Estate Value Prediction Using Linear Regression. In: FOURTH INTERNATIONAL CONFERENCE ON COMPUTING COMMUNICATION CONTROL AND AUTOMATION. Pune: IEEE, 2018.

GU, G.; XU, B. Housing market hedonic price study based on boosting regression tree. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, v. 21, n. 6, p. 1.040-1.047, 2017. DOI: <https://doi.org/10.20965/jaciii.2017.p1040>

GUO, J.-Q. et al. Can machine learning algorithms associated with text mining from internet data improve housing price prediction performance? **International Journal of Strategic Property Management**, [S.l.], 2020.

HJORT, A. et al. House price prediction with gradient boosted trees under different loss functions. **Journal of Property Research**, [S.l.], p. 338-364, 2022.

HO, W. K.; TANG, B.-S.; WONG, S. W. Predicting property prices with machine learning algorithms. *Journal of Property Research*, [S.l.], v. 38, n. 1, p. 48-70, 2020. DOI: <https://doi.org/10.1080/09599916.2020.1832558>.

JA'AFAR, N.; MOHAMAD, J.; ISMAIL, S. Machine learning for property price prediction and price valuation: a systematic literature review. *Journal of the Malaysian Institute of Planners*, [S.l.], v. 19, n. 3, p. 411-422, 2021.

JAIN, M. et al. Prediction of House Pricing using Machine Learning with Python. In: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON ELECTRONICS AND SUSTAINABLE COMMUNICATION SYSTEMS. Pune: IEEE, 2020.

James, G. et al. **An Introduction to Statistical Learning**, 8. ed. (S.l.): Springer, 2017.

JAROSZ, M. et al. Machine Learning Models for Real Estate Appraisal Constructed Using Spline Trend Functions. In: ASIAN CONFERENCE ON INTELLIGENT INFORMATION AND DATABASE SYSTEMS. Phuket: Springer, 2020.

KABAIYANOV, S.; MARKOVSKA, V. Artificial intelligence in real estate market analysis. In: AIP CONFERENCE PROCEEDINGS, v. 2333, p. 030001. **Tomsk: American Institute of Physics**, 2021. DOI: <https://doi.org/10.1063/5.0041806>.

KANG, Y. et al. Understanding house price appreciation using multi-source big geo-data and machine learning. *Land Use Policy*, [S.l.], p. 111, 2020. DOI: <https://doi.org/10.1016/j.landusepol.2020.104919>.

- KIM, J. et al. .A Comparative Study of Machine Learning and Spatial Interpolation Methods for Predicting House Prices. **Sustainability**, [S.l.], v. 14, p. 9056, 2022.
- KUMAR, E. S. et al. Location identification for real estate investment using data analytics. **International Journal of Data Science and Analytics**, [S.l.], p. 299-323, 2019.
- KUVALEKAR, A. et al. House Price Forecasting Using Machine Learning. In: PROCEEDINGS OF THE 3rd INTERNATIONAL CONFERENCE ON ADVANCES IN SCIENCE & TECHNOLOGY (ICAST). [S.l.]: Springer Nature Link, 2020.
- LAHMIRI, S.; BEKIROS, S.; AVDOULAS, C. A comparative assessment of machine learning methods for predicting housing prices using Bayesian optimization. **Decision Analytics Journal**, [S.l.], 2023.
- LEE, C. Training and interpreting machine learning models: application in property tax assessment. **Real Estate Management and Valuation**, v. 30, n. 1, p. 13-22, 2022.
- LEVANTESI, S.; PISCOPO, G. The importance of economic variables on London real estate market: a random forest approach. **Risks**, [S.l.], p. 1-17, 2020.
- LI, S. et al. Understanding the Effects of Influential Factors on Housing Prices by Combining Extreme Gradient Boosting and a Hedonic Price Model (XGBoost-HPM). **Land**, [S.l.], 2021.
- LIMA NETO, V. C. **O uso do imposto de transmissão de bens intervivos para o monitoramento do mercado imobiliário**: uma metodologia para construção do observatório. Brasília: IPEA, 2015.
- LOPES, C. M.; MENDES, J. C. Ética e inteligência artificial: desafios e melhores práticas. Revista da UFMG, v. 30, n. fluxo contínuo, 2023. Disponível em: <https://periodicos.ufmg.br/index.php/revistadaufmg/article/view/47673>. Acesso em: 30 abr. 2023.
- LUCA, A. R. et al. Impact of quality, type and volume of data used by deep learning models in the analysis of medical images. *Informatics in Medicine Unlocked*, [S.l.], v. 29, 2022.
- LYDIA, E. L. et al. Electronic governance of housing price using boston dataset implementing through deep learning mechanism. **International Journal of Recent Technology and Engineering**, [S.l.], p. 560-563, 2019.
- MANJULA, R. et al. Real estate value prediction using multivariate regression models. **IOP Conference Series: Materials Science and Engineering**, [S.l.], 2017.

MARZAGÃO, T.; FERREIRA, R.; SALES, L. A note on real estate appraisal in Brazil. **Revista Brasileira de Economia**, [S.l.], p. 29-36, 2021.

Masrom, S. et al. Automated machine learning based on genetic programming: A case study on a real house pricing dataset. In: 1st INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND DATA SCIENCE. Ipoh: IEEE, 2019.

MEHRABI, N. et al. A Survey on Bias and Fairness in Machine Learning. **ACM Computing Surveys**, [S.l.], 2021.

MOHD, T.; MASROM, S.; JOHARI, N. Machine learning housing price prediction in petaling jaya, Selangor, Malaysia. **International Journal of Recent Technology and Engineering**, [S.l.], p. 542-546, 2019.

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. Foundations of Machine Learning. 2. ed. [S.l.]: MIT Press, 2018.

MORA-GARCIA, R.-T.; CESPEDES-LOPEZ, M.-F.; PEREZ-SANCHEZ, V. Housing Price Prediction Using Machine Learning Algorithms in COVID-19 Times. **Land**, [S.l.], v. 11, n. 2100, p. 1-32, 2022.

MRSIC, L.; JERKOVIC, H.; BALKOVIC, M. Real Estate Market Price Prediction Framework Based on Public Data Sources with Case Study from Croatia. **Intelligent Information and Database Systems**. (pp. 13-24). Phuket: Springer, p. 13-24, 2020. DOI: https://doi.org/10.1007/978-981-15-3380-8_2.

NEJAD, M. Z.; LU, J.; BEHBOOD, V. Applying dynamic Bayesian tree in property sales price estimation. In: 12th INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEMS AND KNOWLEDGE ENGINEERING (ISKE). NanJing: IEEE, p. 1-6, 2017. DOI: <https://doi.org/10.1109/ISKE.2017.8258810>.

NIU, J.; NIU, P. An intelligent automatic valuation system for real estate based on machine learning. *Proceedings of the International Conference on Artificial Intelligence, Information Processing and Cloud Computing*. Sanya: Association for Computing Machinery, 2019.

OLADUNNI, T.; SHARMA, S.; TIWANG, R. A spatio-temporal hedonic house regression model. In: 16th IEEE INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND APPLICATIONS (ICMLA). Cancún: IEEE, p. 607-612, 2017. DOI: <https://doi.org/10.1109/ICMLA.2017.00-94>.

OLIVEIRA JÚNIOR, C. d. **Medium**, 2021. (Recuperado em abril 30, 2023). Disponível em: <https://medium.com/data-hackers/prevendo-n%C3%BAmoros-entendendo-m%C3%A9tricas-de-regress%C3%A3o-35545e011e70>. Acesso em: 30 set. 2023.

PAI, P.-F.; WANG, W.-C. Using Machine Learning Models and Actual Transaction Data for Predicting Real Estate Prices. **Applied Sciences**, [S.l.], p. 1-11, 2020.

PAIXÃO, R. F. et al. Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization. **IBRACON Structures and Materials Journal**, [S.l.], 2022.

PENG, T.-C. The effect of hazard shock and disclosure information on property and land prices: a machine-learning assessment in the case of Japan. **Review of Regional Research**, [S.l.], p. 1-32, 2021.

PHAN, T. D. Housing Price Prediction Using Machine Learning Algorithms: The Case of Melbourne City, Australia. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND DATA ENGINEERING (ICMLDE), Sidney, p. 35-42, 2018. DOI: <https://doi.org/10.1109/ICMLDE.2018.00017>.

RICO-JUAN, J. R.; DE LA PAZ, P. T. Machine learning with explainability or spatial hedonics tools? An analysis of the asking prices in the housing market in Alicante, Spain. *Expert Systems with Applications*, [S.l.], v. 171, p. 114590, 2021. DOI: <https://doi.org/10.1016/j.eswa.2021.114590>.

RIZUN, N.; BAJ-ROGOWSKA, A. Can Web Search Queries Predict Prices Change on the Real Estate Market? **IEEE Access**. DOI: <https://doi.org/10.1016/j.eswa.2021.114590>, p. 70.095-70.117, 2021.

ROOT, T.; STRADER, T.; HUANG, Y.-H. A Review of Machine Learning Approaches for Real Estate Valuation. **Journal of the Midwest Association for Information Systems**, [S.l.], p. 1-20, 2023.

SCOPUS. **Scopus**. [S.l.], 2022. (Recuperado em Agosto 15, 2021.) from. Disponível em: https://service.elsevier.com/app/answers/detail/a_id/15534/supporthub/scopus/#tips. Acesso em: 15 ago. 2021.

SIBINDI, R.; MWANGI, R.; WAITITU, A. A boosting ensemble learning based hybrid light gradient boosting machine and extreme gradient boosting model for predicting house prices. **Engineering Reports**, [S.l.], 2023.

SILVA, G. H. Modelos de aprendizagem de máquina para precificação de imóveis na cidade de Fortaleza. Fortaleza: Universidade Federal do Ceará, 2019.

SINGH, S. et al. , Free Hold Price Predictor Using Machine Learning. **International Journal of Electrical and Electronics Research**, [S.l.], p. 138-143, 2022.

SUTTON, R.; BARTO, A. **Reinforcement Learning: an Introduction**. 2. ed. Cambridge, MA: The MIT Press, 2018.

- TALAGA, M. et al. Apartment valuation models for a big city using selected spatial attributes. *Computational Collective Intelligence*, 11,683,. Hendaia: Springer, Cham, p. 363-376, 2019.
- TANG, J. et al. Using Geographic Information and Point of Interest to Estimate Missing Second-Hand Housing Price of Residential Area in Urban Space. In: IEEE INTERNATIONAL SMART CITIES CONFERENCE. Kansas: IEEE, 2018.
- TCHUENTE, D.; NYAWA, S. Real estate price estimation in French cities using geocoding and machine learning. **Annals of Operations Research**, cidade, p. 571-608, 2021. DOI: <https://doi.org/10.1007/s10479-021-03932-5>.
- TEJASWI, V. S.; SATYANARAYANA, K. V. House Sale Price Prediction using Advanced Regression Techniques and AutoML (TPOTRegressor). **International Journal of Emerging Trends in Engineering Research**, [S.l.], p. 1.373-1.378, 2020.
- TEKIN , M.; SARI, I. Real estate market price prediction model of Istanbul. **Real Estate Management and Valuation**, [S.l.], p. 1-15, 2022.
- TEOH, E.; YAU, W.-C. Explainable housing price prediction with determinant analysis. **International Journal of Housing Markets and Analysis**, [S.l.], p. 1.021-1.045, 2022.
- TRAWINSKI, B. et al. Comparison of Ensemble Learning Models with Expert Algorithms Designed for a Property Valuation System. *Computational Collective Intelligence*, 10448. Chipre: Springer, Cham, p. 317-327, 2017. DOI: https://doi.org/10.1007/978-3-319-67074-4_31.
- TRAWINSKI, B. et al. Comparison of expert algorithms with machine learning models for real estate appraisal. In: IEEE INTERNATIONAL CONFERENCE ON INNOVATIONS IN INTELLIGENT SYSTEMS AND APPLICATIONS. Gdynia: IEEE, 2017.
- VARMA, A. et al. House Price Prediction Using Machine Learning and Neural Networks. In: SECOND INTERNATIONAL CONFERENCE ON INVENTIVE COMMUNICATION AND COMPUTATIONAL TECHNOLOGIES. Coimbatore: IEEE, 2018.
- YAGMUR, A.; KAYAKUS, M.; TERZIOGLU, M. House price prediction modeling using machine learning techniques: a comparative study. **Aestimum**, [S.l.], p. 39-51, 2022.
- YE, Y. et al. Daily accessed street greenery and housing price: measuring economic performance of human-scale streetscapes via new urban data. **Sustainability**, [S.l.], p. 1-21, 2019.
- ZAKI, J. et al. House price prediction using hedonic pricing model and machine learning techniques. **Concurrency Computat Pract Exper**, [S.l.], 2022.

ZHAO, J. et al. Deep CNN-based methods to evaluate neighborhood-scale urban valuation through street scenes perception. In: IEEE THIRD INTERNATIONAL CONFERENCE ON DATA SCIENCE IN CYBERSPACE (DSC). Guangzhou: IEEE, p. 20-27, 2018. DOI: <https://doi.org/10.1109/DSC.2018.00012>.

ZHOU, Y. Housing Sale Price Prediction Using Machine Learning Algorithms. Los Angeles: UCLA, 2020.

ZULKIFLEY, N. H. et al. House Price Prediction using a Machine Learning Model: a Survey of Literature. I.J. **Modern Education and Computer Science**, [S.l.], v. 9, 2020.

2.8 Apêndice A

Tabela 2 - Trabalhos Detectados pela Metodologia

Título	Ano	Citação
Real estate value prediction using multivariate regression models	2017	(Manjula, Jain, Srivastava, & Kher, 2017)
Housing market hedonic price study based on boosting regression tree	2017	(Gu & Xu, 2017)
Comparison of expert algorithms with machine learning models for real estate appraisal	2017	(Trawinski, et al., 2017)
Applying dynamic Bayesian tree in property sales price estimation	2017	(Nejad, Lu, & Behbood, 2017)
A spatio-temporal hedonic house regression model	2017	(Oladunni, Sharma, & Tiwang, 2017)
Comparison of Ensemble Learning Models with Expert Algorithms Designed for a Property Valuation System	2017	(Trawiński, Lasota, Kempa, Telec, & Kutrzyński, 2017)
Identifying Real Estate Opportunities Using Machine Learning	2018	(Baldominos A. , et al., 2018)
Investigation of Florida Housing Prices using Predictive Time	2018	(Aderibigbe & Chi, 2018)
Housing Price Prediction Using Machine Learning Algorithms: The Case of Melbourne City, Australia	2018	(Phan, 2018)
House Price Prediction Using Machine Learning and Neural Networks	2018	(Varma, Sarma, Doshi, & Nair, 2018)
Deep CNN-based methods to evaluate neighborhood-scale urban valuation through street scenes perception	2018	(Zhao, Liu, Kuang, Chen, & Yang, 2018)
Real Estate Value Prediction Using Linear Regression	2018	(Ghosalkar & Dhage, 2018)
Housing Prices Prediction with a Deep Learning and Random Forest Ensemble	2019	(Afonso, Melo, Oliveira, Samuel, & Berton, 2019)
Estimation of missing prices in real-estate market agent-based simulations with machine learning and dimensionality reduction methods	2019	(García-Magariño, Medrano, & Delgado, 2020)
Sensitivity Analysis of Machine Learning Models for the Mass Appraisal of Real Estate. Case Study of Residential Units in Nicosia, Cyprus	2019	(Dimopoulos & Bakas, 2019)
Location identification for real estate investment using data analytics	2019	(Kumar, Talasila, Risha, Kumar, & Iyengar, 2019)
Automated machine learning based on genetic programming: A case study on a real house pricing dataset	2019	(Masrom, Mohd, Jamil, Rahman, & Baharun, 2019)
Machine learning housing price prediction in petaling jaya, Selangor, Malaysia	2019	(Mohd, Masrom, & Johari, 2019)
Electronic governance of housing price using boston dataset implementing through deep learning mechanism	2019	(Lydia, Bindu, Sirisham, & Kiran, 2019)
Using Geographic Information and Point of Interest to Estimate Missing Second-Hand Housing Price of Residential Area in Urban Space	2019	(Tang, Liu, Wang, Yang, & Wang, 2018)
Artificial intelligence for mass appraisals of residential properties in Nicosia: Mathematical modelling and algorithmic implementation	2019	(Dimopoulos & Bakas, 2019)
Apartment valuation models for a big city using selected spatial attributes	2019	(Talaga, et al., 2019)

Título	Ano	Citação
Daily accessed street greenery and housing price: Measuring economic performance of human-scale streetscapes via new urban data	2019	(Ye, Xie, Fang, Jiang, & Wang, 2019)
An intelligent automatic valuation system for real estate based on machine learning	2019	(Niu & Niu, 2019)
A Gradient Boosting Method for Effective Prediction of Housing Prices in Complex Real Estate Systems	2020	(Almaslukh, 2020)
House Price Forecasting Using Machine Learning	2020	(Kuvalekar, Manchewar, Mahadik, & Jawale, 2020)
Predicting Days on Market to Optimize Real Estate Sales Strategy	2020	(Castelli, Dobрева, Henriques, & Vanneschi, 2020)
Predicting property prices with machine learning algorithms	2020	(Ho, Tang, & Wong, 2020)
Real Estate Market Data Analysis and Prediction Based on Minor Advertisements Data and Locations' Geo-codes	2020	(Al-Sit & Al-Hamadin, 2020)
Using Machine Learning Models and Actual Transaction Data for Predicting Real Estate Prices	2020	(Pai & Wang, 2020)
House Price Prediction using Machine Learning Algorithm - The Case of Karachi City, Pakistan	2020	(Ahtesham, Bawany, & Fatima, 2020)
House Sale Price Prediction using Advanced Regression Techniques and AutoML (TPO-TRegressor)	2020	(Tejaswi & Satyanarayana, 2020)
The importance of economic variables on London real estate market: A random forest approach	2020	(Levantesi & Piscopo, 2020)
Prediction of House Pricing using Machine Learning with Python	2020	(Jain, Rajput, Garg, & Chawala, 2020)
Understanding house price appreciation using multi-source big geo-data and machine learning	2020	(Kang, et al., 2020)
Machine Learning Models for Real Estate Appraisal Constructed Using Spline Trend Functions	2020	(Jarosz, et al., 2020)
Real Estate Market Price Prediction Framework Based on Public Data Sources with Case Study from Croatia	2020	(Mrsic, Jerkovic, & Balkovic, 2020)
Efficient Approaches for House Pricing Prediction by Using Hybrid Machine Learning Algorithms	2020	(Chiramel, Logofatu, Rawat, & Andersson, 2020)
Can machine learning algorithms associated with text mining from internet data improve housing price prediction performance?	2020	(Guo, Chiang, Liu, Yang, & Guo, 2020)
A Real Estate Valuation Model Using Boosted Feature Selection	2021	(Chanasit, Chuangsuwanich, Suchato, & Punyabukkana, 2021)
Advanced Machine Learning Algorithms for House Price Prediction: Case Study in Kuala Lumpur	2021	(Abdul-Rahman, Mutalib, & Zulkifley, 2021)
Artificial intelligence in real estate Market analysis	2021	(Kabaivanov & Markovska, 2021)
Machine learning with explainability or spatial hedonics tools? An analysis of the asking prices in the housing market in Alicante, Spain	2021	(Rico-Juan & de La Paz, 2021)
Real estate price estimation in French cities using geocoding and machine learning	2021	(Tchuenta & Nyawa, 2021)
Understanding the Effects of Influential Factors on Housing Prices by Combining Extreme Gradient Boosting and a Hedonic Price Model (XGBoost-HPM)	2021	(Li, Jiang, Ke, Nie, & Wu, 2021)
The effect of hazard shock and disclosure information on property and land prices: a machine-learning assessment in the case of Japan	2021	(Peng, 2021)
A note on real estate appraisal in Brazil	2021	(Marzagão, Ferreira, & Sales, 2021)
Can Web Search Queries Predict Prices Change on the Real Estate Market?	2021	(Rizun & Baj-Rogowska, 2021)
Training and interpreting machine learning models: application in property tax assessment	2022	(Lee, 2022)
Real estate market price prediction model of Istanbul	2022	(Tekin & Sari, 2022)
Property valuation using machine learning algorithms on statistical areas in Greater Sydney, Australia	2022	(Gao, Shi, Pettit, & Han, 2022)
Housing Price Prediction Using Machine Learning Algorithms in COVID-19 Times	2022	(Mora-Garcia, Cespedes-Lopez, & Perez-Sanchez, 2022)
House price prediction with gradient boosted trees under different loss functions	2022	(Hjort, Pensar, Scheel, & Sommervoll, 2022)

Título	Ano	Citação
House price prediction using hedonic pricing model and machine learning techniques	2022	(Zaki, Nayyar, Dalal, & H. Ali, 2022)
House price prediction modeling using machine learning techniques: a comparative study	2022	(Yağmur, Kayakuş, & Terzioğlu, 2022)
Free Hold Price Predictor Using Machine Learning	2022	(Singh, Singh, Yadav, & Kumar, 2022)
Explainable housing price prediction with determinant analysis	2022	(Teoh & Yau, 2022)
Comparison of machine learning models to provide preliminary forecasts of real estate prices	2022	(Chou, Fleshman, & Truong, 2022)
A Comparative Study of Machine Learning and Spatial Interpolation Methods for Predicting House Prices	2022	(Kim, Lee, Lee, & Hong, 2022)
The Use of Machine Learning in Real Estate Research	2023	(Choy & Ho, 2023)
Machine learning methods for prediction real estate sales prices in Turkey	2023	(Çilgin & Gökçen, 2023)
A comparative assessment of machine learning methods for predicting housing prices using Bayesian optimization	2023	(Lahmiri, Bekiros, & Avdoulas, 2023)
A boosting ensemble learning based hybrid light gradient boosting machine and extreme gradient boosting model for predicting house prices	2023	(Sibindi, Mwangi, & Waititu, 2023)

Fonte: Autores.

2.9 Sobre os(as) autores(as)

Romário Parreira Pita é mestre em Ciências da Engenharia Civil na área de concentração de Materiais e Construção pelo Programa de Pós-graduação em Engenharia Civil da Universidade Federal de Ouro Preto (UFOP). Possui especializações em Sustentabilidade na Construção Civil e Engenharia de Segurança do Trabalho. Tem experiências em patologias das construções, certificações de sustentabilidade para edificações, aprendizagem de máquina aplicada ao mercado imobiliário e docência em diversas áreas da engenharia civil.

Aldo Ribeiro de Carvalho é professor no Instituto Federal do Sudeste de Minas Gerais (IF Sudeste MG), Campus Juiz de Fora, no núcleo de Construção Civil, e doutorando em Engenharia Civil na Universidade Federal de Ouro Preto (UFOP). Atualmente é membro do Ative-CNPq - Grupo de Pesquisas de Cimentos Alcali-Ativados e Ácidos-Ativados e do CIDENG-CNPq - Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia. Possui especializações em Docência no Ensino Superior, Engenharia de Segurança do Trabalho e em Gestão Pública em Defesa Civil. Tem experiências em patologias das construções, compósitos cimentícios, compósitos geopoliméricos ácidos e alcalinos, reaproveitamento de resíduos e aplicações de nanomateriais em materiais de construção.

Rafaela Miranda Barbosa é graduanda em Engenharia Civil na Universidade Federal de Juiz de Fora (UFJF). Participou do Programa de Educação Tutorial (PET Civil) entre 2021 e 2022, no qual desenvolveu atividades que visavam melhorar a graduação e adquiriu experiência na área de aprendizagem de máquina aplicada a problemas de engenharia. Atualmente é monitora da disciplina Mecânica dos Solos I.

Alexandre Abrahão Cury é Engenheiro Civil pela UFJF, mestre em Modelagem Computacional pela mesma instituição e doutor em Engenharia Civil pela École Nationale des Ponts et Chaussées. Suas pesquisas abordam monitoramento de integridade estrutural, machine learning e confiabilidade estrutural. Foi coordenador do PPG em Engenharia Civil da UFJF e membro da Câmara de Assessoramento de Arquitetura e Engenharias da FAPEMIG e da Comissão de Avaliação das Engenharias I da CAPES (2017-2021). É pesquisador de Produtividade do CNPq desde 2013, membro do Comitê de Assessoramento do CNPq e editor de Build Engineering e Structural Sensing.

Júlia Castro Mendes é professora na Universidade Federal de Juiz de Fora (UFJF) e docente Permanente dos Programas de Pós-Graduação em Engenharia Civil da UFOP (PROPEC/UFOP) e da UFJF (PEC/UFJF). Coordenadora do CIDENG-CNPq - Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia. Representante brasileira da WREN - Women's Research Engineers Network. Tem experiência na área de aprendizagem de máquina aplicada à materiais de construção, materiais e técnicas de construção sustentáveis, reaproveitamento de resíduos sólidos, propriedades térmicas de matrizes cimentícias e eficiência energética em edificações.

3 INTELIGÊNCIA ARTIFICIAL APLICADA A COMPÓSITOS GEOPOLIMÉRICOS: UMA REVISÃO SISTEMÁTICA DA LITERATURA

Aldo Ribeiro de Carvalho¹, Romário Parreira Pita¹, Thaís Mayra de Oliveira²,
Guilherme Jorge Brigolini Silva¹, Júlia Castro Mendes^{1,2}

¹ Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Ouro Preto.

² Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Juiz de Fora.

3.1 Resumo

Este trabalho tem como objetivo apresentar e analisar estudos que relacionam a Inteligência Artificial (IA) com compósitos geopoliméricos, tanto ácidos quanto alcalinos, por meio de uma revisão sistemática da literatura. A pesquisa foi realizada na base de dados Scopus, abrangendo o período de 2015 a 2023, e resultou na análise de 48 artigos. Esses estudos demonstraram que a IA tem sido principalmente utilizada para prever a resistência à compressão e o abatimento do concreto. No entanto, ao comparar os R^2 das técnicas de IA utilizadas, não se observou uma tendência clara, ou seja, nenhum algoritmo se destacou de forma consistente. Além disso, identificou-se uma carência de estudos que explorem a aplicação da IA em outras propriedades dos compósitos, como resistência ao fogo, durabilidade, porosidade e propriedades térmicas. Em conclusão, este estudo destaca que a IA é uma ferramenta promissora para o desenvolvimento de compósitos geopoliméricos, com potencial para otimizar tempo e recursos, além de oferecer novas oportunidades para pesquisas experimentais em áreas ainda pouco exploradas.

Palavras-Chave: Geopolímeros; Previsão de Resistência à Compressão; Inteligência Artificial; Aprendizado de Máquina; Desempenho de Algoritmos

3.2 Introdução

Os geopolímeros são aglomerantes alternativos, que emitem até 80% menos CO₂ que as matrizes de cimento Portland (Duxson; Provis; Lukey; Deventer, 2007). Investigados principalmente a partir da década de 1980, os compósitos geopoliméricos possuem alta resistência à compressão, alta estabilidade térmica, baixa permeabilidade, baixa retração e resistência ao ataque químico (Davidovits, 2020).

Para produção de um ligante geopolimérico é necessário um agente precursor reativo e um agente ativador (Carvalho; Calderón-Morales; Borba Júnior; Oliveira; Silva, 2023). O precursor é tipicamente composto por silício, alumínio e ferro, preferencialmente em estado amorfo (Carvalho; Calderón-Morales; Borba Júnior; Oliveira; Silva, 2023). Alguns dos materiais precursores mais utilizados no mundo são o metacaulim, sílica amorfa, escória de alto forno, cinza volante e outros subprodutos industriais (Davidovits, 2020). Por sua vez, o agente ativo é uma substância alcalina ou ácida, que pode estar em formato líquido ou sólido (Carvalho; Calderón-Morales; Borba Júnior; Oliveira; Silva, 2023). Dentre os agentes ativos mais conhecidos no meio alcalino estão os hidróxidos de sódio e potássio, alcalissilicatos solúveis que originam os tipos poli(silicatos), poli(siloxo), poli(sílico-aluminatos) e poli(sialato); para os meios ácidos, o ácido fosfórico é o principal agente ativo (Davidovits, 2020).

São diversos fatores que influem as propriedades dos compósitos geopoliméricos, entre eles: a granulometria do precursor (Louati; Baklouti; Samet, 2016); a composição química do material (Mathivet et al., 2019); as fases cristalinas e amorfas do precursor (Carvalho,; Mendes; Oliveira; Silva, 2023); a concentração molar da solução ativadora (Tang et al., 2022); a relação solução ativadora/material precursor (Douri; Louati; Baklouti; Arous; Fakhfakh, 2014; Douri; Louati; Baklouti; Arous; Fakhfakh, 2016); e a temperatura durante a geopolimerização (Carvalho; Calderón-Morales; Borba Júnior; Oliveira; Silva, 2023). Ainda não existem metodologias consolidadas para a definição de traços de matrizes geopoliméricas. Dada essa ampla variedade de fatores, é importante buscar alternativas que otimizem a produção de geopolímeros, evitando a necessidade de testar vários traços em laboratório, o que consome tempo e recursos. Embora os ensaios laboratoriais sejam opções viáveis, eles apresentam diversas limitações, especialmente no Brasil, desde os custos dos materiais até os riscos à segurança ocupacional nos laboratórios (Carvalho, 2024).

Diante disso, as técnicas de Inteligência Artificial (IA) apresentam soluções factíveis para atenuar esses desafios e otimizar o estudo de novos materiais. O aprendizado de máquina (AM) e o aprendizado profundo (AP) são alguns dos campos da IA que permitem a redução da necessidade de testes experimentais no desenvolvimento de materiais (Paixão; Penido; Cury; Mendes, 2022).

Nesse sentido, AM consiste em um conjunto de métodos computacionais capazes de detectar automaticamente padrões nos dados e utilizá-los para fazer

previsões sobre resultados futuros, de forma autônoma (Murphy, 2012). Por sua vez, AP é considerado um subconjunto de IA (alguns autores consideram como um subconjunto de AM) baseado em redes neurais que incluem uma camada de entrada, uma camada de saída e várias camadas ocultas, geralmente, duas ou mais (Lippmann, 1987; Pintelas; Livieris; Kotsiantis; Pintelas, 2023). Em compósitos cimentícios, por exemplo, essas técnicas foram utilizadas para medir a resistência ao cisalhamento (Yaseen; Tran; Kim; Deo, 2018) e à compressão (Hoang; Pham; Nguyen; Pham, 2016) do concreto convencional, além de auxiliar no desenvolvimento de traços de concreto (Penido et al., 2022) e no monitoramento estrutural de empreendimentos (Alves; Cury, 2021; Cardoso; Cury; Barbora, 2018). Dito isto, o presente estudo se dedica a identificar as principais aplicações de IA em compósitos geopoliméricos, ácidos e alcalinos. Para isso foi realizado uma revisão sistemática da literatura entre os anos de 2015 e 2023.

3.3 Metodologia da Revisão

Para realizar a revisão sistemática utilizou-se a *string* de busca em inglês: “(Geopolymer OR Alkali-activated OR Alkali-activated materials OR Phosphate based geopolymers) AND (Artificial Intelligence OR Machine Learning OR Deep Learning)”. Assim, a pesquisa focou na aplicação de métodos de IA em compósitos geopoliméricos alcalinos ou ácidos à base de fosfato, sem restrição quanto ao tipo de compósito (pasta, argamassa ou concreto).

A busca foi feita no banco de dados Scopus, em 2 de janeiro de 2024, utilizando as funcionalidades de busca por “título/resumo/palavra-chave”. O Scopus foi escolhido por sua abrangência e validação prévia (Wuni; Shen; Osei-Kyei, 2019; Meho; Rogers, 2008), além de conter um dos maiores acervos de pesquisa da área da construção civil e ser o maior banco de dados de citações revisadas por pares (Hong; Chan, 2014; Tariq; Hu; Zayed, 2021). As restrições e critérios de seleção ou descarte dos artigos foram:

O recorte temporal adotado foi de 2015 a 2023. Não foram detectadas pela *string* de busca pesquisas anteriores a 2015.

- Nenhum artigo foi excluído pelo filtro “área temática” devido à interdisciplinaridade deste estudo.
- Apenas artigos de periódicos foram considerados em “tipo de documentos”.
- Não houve restrição quanto ao título da fonte, visando obter maior número de estudos sobre o tema.
- Apenas o estágio de publicação “Final” foi considerado, buscando filtrar apenas os artigos já publicados.

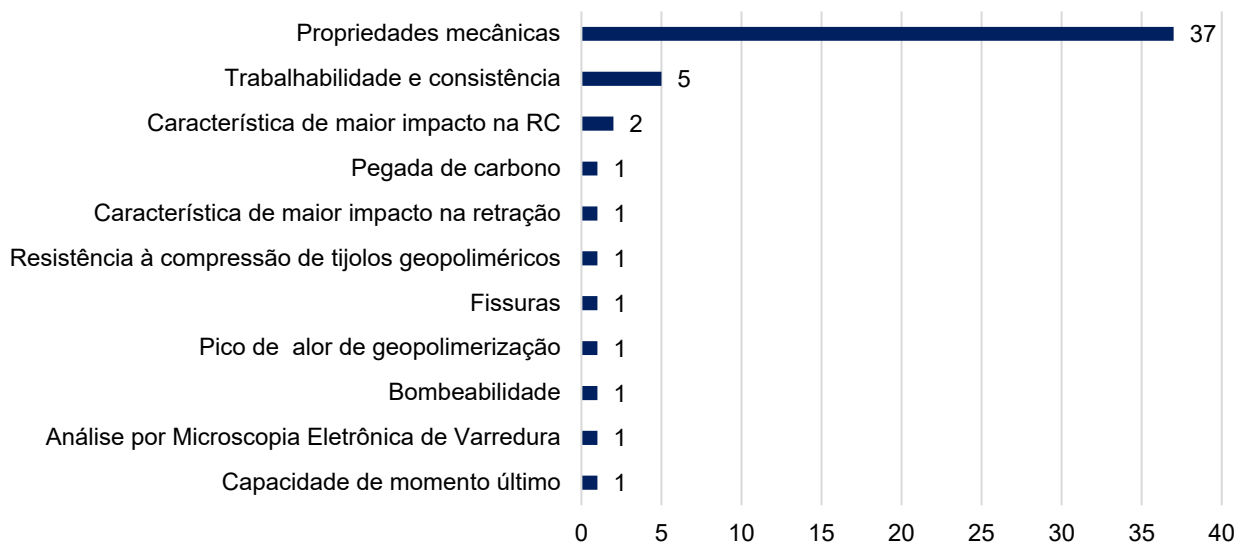
- Apenas artigos de acesso aberto foram aceitos, visando facilitar a replicabilidade do método para outras equipes de pesquisa.
- Por fim, foi realizada a leitura e análise semântica dos resumos, selecionando apenas os que abordassem o uso de ferramentas de IA com materiais geopoliméricos.

Após a aplicação de todos os critérios, restaram 48 estudos para análise, sendo todos publicados a partir de 2018 e que são apresentados no Apêndice A.

3.4 Aplicações de IA em Compósitos Geopoliméricos

A Figura 1 destaca as principais aplicações de IA identificadas na literatura, com 77% dos artigos focados na previsão da resistência mecânica dos compósitos, especialmente a resistência à compressão. Esse ensaio laboratorial, que geralmente requer de 7 a 28 dias para cura e desenvolvimento da resistência, é um processo demorado, exigindo novas amostras a cada iteração. O uso de AM e AP permite testar várias combinações em ambiente simulado, antecipando os resultados dos testes experimentais. Assim, a IA oferece uma alternativa mais ágil de forma relativamente acurada, otimizando tempo e recursos.

Figura 1 – Principais aplicações de IA em Compósitos Geopoliméricos




Fonte: Autores.

3.4.1 Previsão de resistência mecânica

A previsão das propriedades mecânicas dos materiais geopoliméricos desenvolvidos foi o tema de 37 dos 48 estudos avaliados. A Figura 2 reúne os atributos de entrada mais mencionados, que apareceram mais de 5 vezes, usados para alimentar os modelos de IA. Todos os insumos, mencionados na Figura 2, se relacionam com as propriedades dos geopolímeros ou às características de produção, como temperatura

de cura, idade do corpo de prova e aspectos inerentes aos materiais precursores e ativadores. O teor de cinzas volantes (material precursor), o teor de hidróxido de sódio (NaOH) e a molaridade do NaOH (materiais ativadores) foram os atributos mais adotados.

Figura 2 – Principais características / variáveis utilizadas como entrada nos modelos



Fonte: Autores.

Para avaliar a variabilidade nos dados de previsão da resistência à compressão, 36 dos 48 artigos (75%) utilizaram o coeficiente de determinação (R^2) como métrica de desempenho dos algoritmos. Nesse contexto, é importante destacar que, ao aplicar o R^2 em algoritmos de AM e AP, recomenda-se a análise combinada com outras métricas relevantes, como o erro absoluto médio (MAE), o erro percentual absoluto médio (MAPE) ou o erro quadrático médio (RMSE) (James; Witten; Hastie; Tibshirani; Taylor, 2023). Isso se faz necessário porque o R^2 pode ser influenciado por valores atípicos e pode não refletir adequadamente a qualidade do modelo em situações específicas (James; Witten; Hastie; Tibshirani; Taylor, 2023). Em problemas complexos, nos quais a relação entre as variáveis é frequentemente não linear, o R^2 pode oferecer uma visão limitada (James; Witten; Hastie; Tibshirani; Taylor, 2023). Portanto, ao utilizar o R^2 , recomenda-se que a equipe de pesquisa adote uma abordagem mais ampla, incorporando múltiplas métricas para uma compreensão completa do desempenho do modelo. A Tabela 1 apresenta os resultados do R^2 obtido nos estudos de resistência à compressão.

Tabela 1 - R² obtido nos estudos de resistência à compressão

Material	Banco de Dados	Autores	Algoritmos e número de artigos que adotaram cada algoritmo																			
			ADB	AD	ANF	AG	CT	EM	FA	KVPM	MVS	MAE	RB	RG	RL	RLo	RNL	RNA	RNP	RRP	PEG	XGB
			5	6	4	5	1	1	11	2	7	1	2	1	5	1	3	18	2	2	7	2
Pasta	64	(Leong, Ong, Sanjayan, Nazari, & Kueh, 2018)																0,95			0,93	
	307	(Arachchilage, Fan, Zhao, Huang, & Liu, 2023)				0,97				0,91		0,89						0,89				
	282	(Ngo, Nguyen, & Tran, 2023)				0,96				0,95								0,97				0,97
	286	(Nagaraju, Mantena, Gobinath, Bonthu, & Alisha, 2023)								0,96	0,94					0,83						
	283	(Zeini, et al., 2023)								0,99						0,84						
Argamassa	45	(Ristic, et al., 2022)													0,86							
	105	(Chen, et al., 2022)									0,95				0,68							
	247	(Ahmad A. , Ahmad, Aslam, & Joyklad, 2022)														0,83	0,93					
Concreto	210	(Dao, Ly, Trinh, Le, & Pham, 2019)			0,93										0,81							
	210	(Dao, Trinh, Ly, & Pham, 2019)			0,88													0,85				
	263	(Huynh, et al., 2020)															0,92	0,92	0,90			
	105	(Awoyera, Kirgiz, Viloría, & Ovallos-Gazabon, 2020)															0,97				0,64	

Material	Banco de Dados	Autores	Algoritmos e número de artigos que adotaram cada algoritmo																			
			ADB	AD	ANF	AG	CT	EM	FA	KVPM	MVS	MAE	RB	RG	RL	RLo	RNL	RNA	RNP	RRP	PEG	XGB
			5	6	4	5	1	1	11	2	7	1	2	1	5	1	3	18	2	2	7	2
	298	(Khan <i>et al.</i> , 2021)												0,90		0,92					0,96	
	101	(Aneja, Sharma, Gupta, & Yoo, 2021)															0,99					
	298	(Khan, et al., 2021)			0,98												0,93				0,96	
	180	(Gomaa, Han, ElGawady, Huang, & Kumar, 2021)							0,94													
	166	(Gunasekara, Atzarakis, Lokuge, Law, & Setunge, 2021)															0,87					
	154	(Ahmad A. , et al., 2021)	0,94			0,96											0,87					
	311	(Chu, et al., 2021)						0,83													0,86	
	110	(Peng & Unluer, 2022)								0,91							0,93					
	384	(Rahman & Al-Ameri, 2023)									0,91						0,96					
	151	(Cao, Fang, Jin, & Shang, 2022)								0,91							0,88					0,98
	371	(Wang, et al., 2022)	0,90	0,83		0,98			0,90													
	181	(Tang, et al., 2022)															0,99					
	371	(Khan, et al., 2022)	0,97							0,93												
	860	(Emarah, 2022)															0,90	0,90	0,90			
	481	(Amin, et al., 2022)	0,89						0,95	0,78							0,81					
	154	(Ahmad A. , Ahmad, Aslam, & Joyklad, 2022)	0,94	0,90								0,97										

Material	Banco de Dados	Autores	Algoritmos e número de artigos que adotaram cada algoritmo																			
			ADB	AD	ANF	AG	CT	EM	FA	KVPM	MVS	MAE	RB	RG	RL	RLo	RNL	RNA	RNP	RRP	PEG	XGB
			5	6	4	5	1	1	11	2	7	1	2	1	5	1	3	18	2	2	7	2
	147	(Mansouri, Manfredi, & Hu, 2022)		0,96		0,95	0,96															
	371	(Zou, et al., 2022)		0,88						0,95			0,96								0,93	
	156	(Chen, et al., 2022)		0,92						0,94		0,93										
	250	(Upreti, et al., 2022)								0,99							0,99					
	359	(Chen, Zhou, Shi, & Huang, 2023)		0,92						0,98	0,99											
	28	(Esparham & Mehrdadi, 2023)															0,93					
	245	(Nazar, et al., 2023)			0,92												0,91					

ADB – Adaboost | AD – Árvore de Decisão | AG – Aumento de Gradiente | ANF – ANFIS | CT - CatBoost | EM – Expressões Multiplas | FA – Floresta Aleatória | KVPM – KVizinhos Mais Próximos | MVS – Máquina de Vetor de Suporte | MAE – Máquina de Aprendizado Extremo | RB - Regressor Bagging | RG – Regressão Gaussiana | RL – Regressão Linear | RLo – Regressão Logística | RNL – Regressão Não-Linear | RNA – Redes Neurais Artificiais | RNP – Redes Neurais Profundas | RRP – Redes Residuais Profundas | PEG – Programação de Expressão Gênica | XGB - XGBoost

Fonte: Autores.

Entre os resultados observados, os algoritmos de Redes Neurais Artificiais, Floresta Aleatória e K-Vizinho mais Próximo alcançaram índices muito altos, chegando a R^2 de 0,99 nos trabalhos de Aneja et al. (2021); Tang et al. (2022); Upreti et al. (2022); Chen et al. (2023); Zeini et al. (2023); sendo este o valor mais próximo de 1 entre todos os estudos analisados na Tabela 1. No entanto, é essencial ressaltar que valores elevados de R^2 nem sempre indicam uma construção de modelo adequada. Problemas como *overfitting* e vazamento de dados podem resultar em métricas aparentemente boas, mas enganosas. Essa preocupação é ainda maior em alguns estudos que não apresentam de forma clara estratégias para mitigar o *overfitting*, como o uso da validação cruzada. Da mesma forma, um modelo que correlacione bem os dados de corpos de prova elaborados por um único laboratório pode não ser representativo de outras localidades e situações – em outras palavras, um alto R^2 não garante uma boa habilidade de generalização do modelo (Paixão et al., 2022; Lopes; Mendes, 2023).

Com exceção dos estudos de Aneja et al. (2021) e Tang et al. (2022), todos os outros trabalhos utilizaram bancos de dados com mais de 200 instâncias, provenientes tanto da literatura quanto de resultados experimentais. Entre os cinco artigos que contavam com os menores bancos de dados, o algoritmo Programação de Expressão Genética utilizado por Awoyera et al. (2020) apresentou o menor resultado de R^2 , com valor de 0,64. Esse resultado pode ser atribuído ao tamanho limitado do banco de dados, apenas 105 instâncias, em comparação aos outros estudos listados na Tabela 1. Contudo, os mesmos autores obtiveram $R^2 = 0,97$ ao utilizarem Redes Neurais Artificiais com o mesmo conjunto de dados (Awoyera; Kirgiz; Vilorio; Ovallos-Gazabon, 2020). O desempenho inferior não está necessariamente relacionado à técnica de aprendizado de máquina em si, pois Khan et al. (2021) e Khan et al. (2021), alcançaram $R^2 = 0,96$ para o algoritmo Programação de Expressão Genética com seus próprios dados. Esses achados ressaltam a relevância de se escolher o algoritmo de modelagem mais adequado para cada conjunto de dados específico. Outras características da construção do modelo, como pré-tratamento ou normalização dos dados, codificação das variáveis categóricas, bem como o tipo de separação em conjuntos de treino e teste podem influenciar a sua acurácia final; mas grande parte dos trabalhos não especificou claramente essas etapas. Isso é um grande obstáculo ético à maior confiabilidade dos modelos de IA (Lopes; Mendes, 2023).

Entre os estudos que compararam diversos algoritmos, incluindo o Floresta Aleatória, muitos relataram que esse algoritmo obteve o melhor ou o segundo melhor R^2 (Wang et al., 2022; Amin et al., 2022; Chen et al., 2022; Upreti et al., 2022; Zou et al., 2022; Arachchilage; Fan; Zhao; Huang; Liu, 2023; Chen; Zhou; Shi; Huang, 2023; Nagaraju; Mantena; Gobinath; Bonthu; Alisha, 2023; Zeini et al., 2023). Somente Ngo, Nguyen e Tran (2023) não obtiveram o maior ou o segundo maior R^2 com o uso do Random Forest, embora os valores de R^2 ainda tenham se mantido acima de 0,90.

Um desempenho superior semelhante foi observado em artigos que avaliaram os algoritmos Aumento de Gradiente (Ahmad A. et al., 2021; Khan et al., 2022; Mansouri; Manfredi; Hu, 2022; Arachchilage; Fan; Zhao; Huang; & Liu, 2023; Ngo; Nguyen; Tran, 2023), XGBoost (uma evolução do Aumento de Gradiente) (Cao; Fang; Jin; Shang, 2022; Ngo; Nguyen; Tran, 2023), ANFIS (Dao; Trinh; Ly; Pham, 2019; Khan et al., 2021; Nazar et al., 2023), e Regressor de Ensacamento (Ahmad; Ahmad; Aslam; Joyklad, 2022; Zou et al., 2022). Esses resultados indicam que alguns algoritmos podem ser mais adequados para modelar as relações complexas que envolvem os compósitos geopoliméricos do que outros.

O trabalho de Sheiati, Behboodi e Ranjbar (2022) utilizou o Autocodificador Convolutacional Profundo, que emprega imagens como atributos de entrada para prever a resistência à compressão de compósitos cimentícios, por meio da análise de poros e fissuras no material. No entanto, nenhum estudo semelhante foi encontrado sobre compósitos geopoliméricos.

Bagheri e Cremona (2020) desenvolveram um algoritmo para classificar materiais geopoliméricos com base nos fatores mais importantes que influenciam a resistência à compressão, considerando os componentes químicos de suas matérias-primas. Por meio dessa classificação, os autores identificaram que o uso da escória como matéria-prima e o teor de íon boro foram os principais fatores que influenciaram a variação na resistência à compressão das amostras estudadas (Bagheri; Cremona, 2020).

Em contraste com os estudos que avaliaram a resistência à compressão de pastas, argamassas e concretos, apenas um estudo investigou tijolos geopoliméricos (Mahamat et al., 2021). Mahamat et al. (2021) compararam os algoritmos Máquina de Vetor de Suporte, Redes Neurais Artificiais e Regressão Linear, com o Máquina de Vetores de Suporte apresentando o melhor desempenho. Em outra linha de pesquisa, Rahman e Al-Ameri (2023) previram o estado limite de momento último de uma estrutura geopolimérica à base de basalto, utilizando Redes Neurais Artificiais, e obtiveram um R^2 de 0,99. Esses resultados indicam que há muitas oportunidades para a aplicação de modelos de IA em outros materiais e estruturas baseados em geopolímeros, para além dos compósitos convencionais.

3.4.2 Previsão de características do estado fresco

Kong e Kurumisawa (2023) investigaram os efeitos de diversos fatores na trabalhabilidade dos geopolímeros utilizando o algoritmo LightGBM (que se trata de uma técnica de Árvore de Decisão para problemas de regressão (Alabdullah et al., 2022)). Os autores constataram que a fluidez das misturas aumentava quando o teor de silicato estava abaixo de 2,00. Em contrapartida, a trabalhabilidade diminuía

com o aumento da reatividade dos precursores, da concentração molar de NaOH no ativador e da razão volumétrica dos agregados (Kong; Kurumisawa, 2023).

De maneira similar, Hamie et al. (2022), por meio de Análise de Árvore de Decisão e Regressão Logística, identificaram que a relação entre água e material sólido no compósito geopolimérico é o principal fator que determina a consistência do material. Esta mesma conclusão foi corroborada por Gomaa et al. (2021), que verificaram que a quantidade de água era o fator primário que influenciava a trabalhabilidade do concreto geopolimérico. Nazar et al. (2023), em seu estudo comparativo entre os algoritmos ANFIS, Redes Neurais Artificiais e Programação de Expressão Genética, descobriram que o abatimento do compósito geopolimérico aumentava com maiores concentrações de alumínio na composição das cinzas volantes, bem como com o acréscimo de água e de teor de NaOH. Além disso, os autores também observaram que o abatimento diminuía na medida em que o tempo de cura e a concentração molar de NaOH aumentavam.

Hoayek et al. (2023) procuraram avaliar as vantagens e desvantagens dos modelos de Árvore de Decisão e Floresta Aleatória na predição da facilidade de bombeamento dos geopolímeros durante a fase de policondensação. Os autores constataram que o modelo de Árvore de Decisão apresentou um bom desempenho na explicação de relações não-lineares, considerando todas as variáveis independentes, e demonstrou superioridade em termos de simplicidade computacional e clareza algorítmica. Em contrapartida, o modelo de Floresta Aleatória falhou ao não considerar todas as combinações possíveis de variáveis na construção de cada árvore, o que comprometeu sua capacidade de generalização nos conjuntos de teste (Hoayek; Khalifeh; Hamie; El-Ghoul; Zgheib, 2023). Assim, os Hoayek et al. (2023) concluíram que o modelo de Árvore de Decisão foi o mais preciso para prever a bombeabilidade ideal dos geopolímeros.

Chen et al. (2022) investigaram as propriedades de expansão e retração de um compósito geopolimérico utilizando um modelo de Árvore de Decisão. Os autores identificaram que os principais fatores que influenciavam esses fenômenos eram o tipo de cura, o tempo de desmoldagem, a quantidade de óxido de magnésio e a concentração molar de NaOH.

Por fim, Tanyildizi (2021) realizou uma análise inovadora ao estudar os picos de geopolimerização, os picos de calor de geopolimerização e os tempos de dissolução correspondentes para cada um desses picos. O autor aplicou as técnicas de K-Vizinho mais Próximo, Máquinas de Vetores de Suporte para Regressão e Memória de Longo Curto Prazo (LSTM). Entre esses métodos, o modelo de Memória de Longo Curto Prazo demonstrou a maior precisão, identificando que os fatores mais relevantes para a determinação dos picos eram a temperatura de cura e a razão em massa entre a solução ativadora e o material precursor (Tanyildizi, 2021).

3.4.3 *Análise de imagens e previsão de fissuração*

A previsão de fissuras em elementos constituídos por cimento Portland tem sido amplamente abordada na literatura científica sobre IA (Deepak; Andal; Raj; Srinidhi, 2023; Xu; Xu; Forde; Caballero, 2023). No caso de geopolímeros, Li et al. (2021) concentraram-se na previsão e avaliação de fissuras superficiais em geopolímeros reforçados com fibras de polipropileno. Para isso, as vigas foram submetidas a esforços de flexão e suas superfícies foram registradas por meio de fotografias. Essas imagens foram utilizadas como variáveis de entrada em um algoritmo de Programação Dinâmica (DP), que correlacionou o volume de fibras de polipropileno e a resistência à flexão com as características das fissuras capturadas nas fotografias. Li et al. (2021) constataram que o aumento no volume de fibras e na relação água/precursor resultou em um crescimento das dimensões das fissuras nos geopolímeros.

A aplicação de algoritmos de DP para avaliação de imagens também se estende à análise de testes de Microscopia Eletrônica de Varredura (SEM). Em um estudo realizado por Sheiati, Behboodi e Ranjbar (2022), foram empregadas Redes Autocodificadoras Profundas de Convolução, especificamente o modelo SegNet. Os pesquisadores observaram que o algoritmo foi capaz de detectar com precisão a cor e a textura de fundo das imagens de microscopia eletrônica de retroespalhamento (BSE) (Sheiati; Behboodi; Ranjbar, 2022). Com base nesses resultados, os autores sugerem que o SegNet possui potencial para superar técnicas e softwares convencionais na segmentação de imagens BSE-SEM (Sheiati; Behboodi; Ranjbar, 2022).

3.4.4 *Aspectos sustentáveis*

Völker et al. (2021) aplicaram os algoritmos Floresta Aleatória e Regressão Gaussiana para avaliar o impacto das decisões relativas à seleção de materiais sobre as emissões de CO₂. Os resultados indicaram uma redução significativa tanto no tempo necessário para o desenvolvimento dos materiais quanto nos custos associados à pesquisa, impulsionados pela precisão das previsões geradas pelos modelos de IA. A configuração de *design* ideal obtida pelos algoritmos desenvolvidos por Völker et al. (2021) demonstrou um desempenho até 10 vezes superior na mitigação das emissões de CO₂ quando comparada ao design menos eficiente.

3.5 **Considerações Finais**

O presente estudo abordou as aplicações da Inteligência Artificial (IA) no contexto dos geopolímeros ácidos e alcalinos. Para tal, foi conduzida uma revisão sistemática da literatura em 48 artigos de acesso aberto, publicados entre os anos de 2015 e 2023, sendo que os primeiros resultados relevantes foram registrados a partir de 2018. As principais conclusões deste trabalho incluem:

- A maioria dos algoritmos analisados (77%) foi utilizada para prever a resistência mecânica, seguidos por avaliação da trabalhabilidade e bombeabilidade (10%). Poucas outras propriedades foram investigadas, e quando foram, apenas uma vez. As lacunas identificadas incluem a aplicação de IA para outras características, como a resistência ao fogo, durabilidade, propriedades térmicas e aspectos físicos, como o sistema de poros.
- As Redes Neurais Artificiais seguidas da técnica de Floresta Aleatória foram os algoritmos de aprendizado de máquina (AM) mais empregados nas investigações sobre geopolímeros. Os estudos que aplicaram técnicas de aprendizado profundo (AP) concentraram-se, predominantemente, na análise de imagens.
- Ao comparar as diferentes técnicas de AM com seus respectivos coeficientes de determinação (R^2) para previsão de resistência, não se observou uma tendência consolidada, indicando a ausência de um algoritmo universalmente superior. Além disso, o desempenho de um mesmo algoritmo variou entre diferentes bases de dados. Contudo, algoritmos como Floresta Aleatória, Aumento de Gradiente, X GBoost e o ANFIS se destacaram, apresentando o melhor ou segundo melhor resultado em estudos que compararam diversas técnicas. Isso ressalta a necessidade de realizar testes com múltiplos métodos distintos e de construir modelos robustos em termos de pré-processamento, validação e métricas de avaliação na pesquisa de materiais.
- Diversos autores relataram coeficientes de determinação (R^2) extremamente altos, atingindo até 0,99 em algumas investigações. Embora tal resultado seja impressionante, a complexidade e heterogeneidade dos compósitos geopoliméricos coloca dúvidas sobre tal desempenho, que pode ser atribuído a um banco de dados excessivamente homogêneo, ao *overfitting* ou a um possível vazamento de dados.

Este estudo demonstra que a IA é uma ferramenta eficaz e eficiente na economia de tempo e recursos para o desenvolvimento de geopolímeros, quando utilizada de maneira ética e apropriada. As técnicas de IA podem modelar as interações complexas entre os componentes dos compósitos geopoliméricos, permitindo que pesquisadores e profissionais prevejam resultados, classifiquem materiais e compreendam melhor seu comportamento. Ainda existem várias lacunas a serem exploradas neste ramo, e os autores rogam para que os algoritmos de IA sejam construídos segundo as melhores práticas de ética e transparência.

3.6 Agradecimentos

Agradecemos à UFOP (Universidade Federal de Ouro Preto) e à UFJF (Universidade Federal de Juiz de Fora) pela estrutura de laboratório e recursos

materiais. Gostaríamos de expressar nossa gratidão às instituições que ofereceram apoio financeiro para este trabalho: CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), pela bolsa de doutorado concedida a Aldo Ribeiro de Carvalho, código de financiamento 001; CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico, bolsa 305818/2023-6 - Pesquisadora PQ - para Julia Castro Mendes e 312503/2023-7 - Pesquisador PQ - para Guilherme Jorge Brigolini Silva); e FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais – projeto APQ-01904-22 para Thaís Mayra de Oliveira e APQ-01838-21 para Julia Mendes) e FINEP (Financiadora de Estudos e Projetos). Por fim, agradecemos aos grupos de pesquisa ATIVE-CNPq e CIDENG-CNPq pelo apoio e colaboração.

3.7 Referências

AHMAD, A. et al. Compressive strength prediction of fly ash-based geopolymer concrete via advanced machine learning techniques. **Case Studies in Construction Materials**, [S.l.], v. 16, 2022.

AHMAD, A. et al. Prediction of Geopolymer Concrete Compressive Strength Using Novel Machine Learning Algorithms. **Polymers**, [S.l.], v. 13, n. 19, 2021. DOI: <https://doi.org/10.3390/polym13193389>.

ALABDULLAH, A. A. et al. Prediction of rapid chloride penetration resistance of metakaolin based high strength concrete using light GBM and XGBoost models by incorporating SHAP analysis. **Construction and Building Materials**, v. 345, p.128296, 2022. DOI: <https://doi.org/10.1016/j.conbuildmat.2022.128296>.

ALVES, V.; CURY, A. A fast and efficient feature extraction methodology for structural damage localization based on raw acceleration measurements. **Structural Control and Health Monitoring**, [S.l.], v. 28, n. 7, p. e2.748, 2021.

AMIN, M. N. et al. Compressive Strength Estimation of Geopolymer Composites through Novel Computational Approaches. **Polymers**, [S.l.], v. 14, n. 10, 2022. DOI: <https://doi.org/10.3390/polym14102128>.

ANEJA, S. et al. Bayesian Regularized Artificial Neural Network Model to Predict Strength Characteristics of Fly-Ash and Bottom-Ash Based Geopolymer Concrete. **Materials**, [S.l.], 2021. DOI: <https://doi.org/10.3390/ma14071729>.

ARACHCHILAGE, C. B. et al. A machine learning model to predict unconfined compressive strength of alkali-activated slag-based cemented paste backfill. **Journal of Rock Mechanics and Geotechnical Engineering**, [S.l.], v. 15, p. 2.803-2.815, 2023. DOI: <https://doi.org/10.1016/j.jrmge.2022.12.009>.

AWOYERA, P. O. et al. Estimating strength properties of geopolymer self-compacting concrete using machine learning techniques. **Journal of Materials Research and Technology**, [S.l.], v. 9, p. 9.016-9.028, 2020.

BAGHERI, A.; CREMONA, C. Formulation of mix design for 3D printing of geopolymers: a machine learning approach. **Materials Advances**, [S.l.], 2020. Disponível em: <https://pubs.rsc.org/en/content/articlelanding/2020/ma/d0ma00036a>. Acesso em: 7 jul. 2025.

CAO, R. et al. Application of machine learning approaches to predict the strength property of geopolymer concrete. **Materials**, [S.l.], 2022. Disponível em: <https://www.mdpi.com/1996-1944/15/7/2400>. Acesso em: 7 jul. 2025.

CARDOSO, R. A.; CURY, A.; BARBORA, F. A clustering-based strategy for automated structural modal identification. **Structural Health Monitoring**, [S.l.], v. 18, p. 201–217, 2018.

CARVALHO, A. R. Occupational risks in the technological development of construction materials at Brazilian public universities. **Revista de Gestão Social e Ambiental**, [S.l.], v. 18, n. 6, 2024. DOI: <https://doi.org/10.24857/rgsa.v18n6-199>.

CARVALHO, A. R. et al. Proposition of geopolymers obtained through the acid activation of iron ore tailings with phosphoric acid. **Construction and Building Materials**, [S.l.], 2023. DOI: <https://doi.org/10.1016/j.conbuildmat.2023.133078>.

CARVALHO, A. R. et al. Potencial do uso dos resíduos industriais originados no estado de Minas Gerais como precursores geopoliméricos. In: ENCONTRO NACIONAL DE APROVEITAMENTO DE RESÍDUOS NA CONSTRUÇÃO: CIRCULARIDADE E SUSTENTABILIDADE, 2023, Foz do Iguaçu, 2023.

CHEN, K. et al. Predicting the geopolymerization process of fly-ash-based geopolymer using machine learning. **Buildings**, [S.l.], 2022. DOI: <https://doi.org/10.3390/buildings12111792>.

CHEN, S. et al. A novel MBAS-RF approach to predict mechanical properties of geopolymer-based compositions. **Gels**, [S.l.], 2023. DOI: <https://doi.org/10.3390/gels9060434>.

CHEN, Y.-C. et al. The length change ratio of ground granulated blast furnace slag-based geopolymer blended with magnesium oxide cured in various environments. **Polymers**, [S.l.], 2022. DOI: <https://doi.org/10.3390/polym14163386>.

CHU, H. H. et al. Sustainable use of fly-ash: use of gene-expression programming (GEP) and multi-expression programming (MEP) for forecasting the compressive strength of geopolymer concrete. **Ain Shams Engineering Journal**, [S.l.], v. 12, p. 3.603–3.617, 2021.

DAO, D. V. et al. Artificial intelligence approaches for prediction of compressive strength of geopolymer concrete. **Materials**, [S.l.], 2019. Disponível em: <https://www.mdpi.com/1996-1944/12/6/983>. Acesso em: 7 jul. 2025.

DAO, D. V. et al. Prediction of compressive strength of geopolymer concrete using entirely steel slag aggregates: novel hybrid artificial intelligence approaches. *Applied Sciences*, Suíça, 2019. Disponível em: <https://www.mdpi.com/2076-3417/9/6/1113>. Acesso em: 7 jul. 2025.

DAVIDOVITS, J. Geopolymer: chemistry & applications. 3. ed. França: Geopolymer Institute, 2020.

DEEPAK, M. et al. Crack width prediction of RC beams by artificial neural networks. **Materials Today: proceedings**, [S.l.], 2023. DOI: <https://doi.org/10.1016/j.matpr.2023.05.377>.

DOURI, H. et al. Enhanced dielectric properties of phosphoric acid-based geopolymers with different amounts of H₃PO₄. **Materials Letters**, [S.l.], p. 9-12, 2014.

DOURI, H. et al. Enhanced dielectric performance of metakaolin-H₃PO₄ geopolymers. **Materials Letters**, [S.l.], p. 299-302, 2016.

DUXSON, P. et al. The role of inorganic polymer technology in the development of 'green concrete'. **Cement and Concrete Research**, [S.l.], v. 37, n. 12, p. 1.590–1.597, 2007.

EMARAH, D. A. Compressive strength analysis of fly ash-based geopolymer concrete using machine learning approaches. **Results in Materials**, [S.l.], 2022. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2590048X22000954?via%3Dihub>. Acesso em: 7 jul. 2025.

ESPARHAM, A.; MEHRDADI, N. Effect of combined different sources of alumina silicate on mechanical properties and carbonation depth of environmentally friendly geopolymeric composite based on metakaolin. **International Journal of Engineering**, [S.l.], 2023. Disponível em: https://www.ije.ir/article_170844.html. Acesso em: 7 jul. 2025.

GOMAA, E. et al. Machine learning to predict properties of fresh and hardened alkali-activated concrete. **Cement and Concrete Composites**, [S.l.], 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0958946520303681?via%3Dihub>. Acesso em: 7 jul. 2025.

GUNASEKARA, C. et al. Novel analytical method for mix design and performance prediction of high calcium fly ash geopolymer concrete. **Polymers**, [S.l.], 2021. Disponível em: <https://www.mdpi.com/2073-4360/13/6/900>. Acesso em: 7 jul. 2025.

HAMIE, H. et al. Application of non-parametric statistical methods to predict pumpability of geopolymers for well cementing. **Journal of Petroleum Science and Engineering**, [S.l.], v. 212, 2022.

HOANG, N. D. et al. Estimating compressive strength of high-performance concrete with Gaussian process regression model. **Advances in Civil Engineering**, [S.l.], 2016. DOI: <https://doi.org/10.1155/2016/2861380> .

HOAYEK, A. et al. Prediction of geopolymer pumpability and setting time for well zonal isolation – using machine learning and statistical based models. **Heliyon**, [S.l.], 2023. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2405844023051332>. Acesso em: 7 jul. 2025.

HONG, Y.; CHAN, D. W. Research trend of joint ventures in construction: a two-decade taxonomic review. **Journal of Facilities Management**, [S.l.], p. 118–141, 2014. DOI: <https://doi.org/10.1108/JFM-04-2013-0022>.

HUYNH, A. T. et al. A machine learning-assisted numerical predictor for compressive strength of geopolymer concrete based on experimental data and sensitivity analysis. **Applied Sciences**, [S.l.], v. 10, n. 21, 2020.

JAMES, G. et al. **An introduction to statistical learning with applications in R**. 2. ed. [S.l.]: Springer, 2023.

KHAN, K. et al. Assessment of artificial intelligence strategies to estimate the strength of geopolymer composites and influence of input parameters. **Polymers**, [S.l.], 2022. Disponível em: <https://www.mdpi.com/2073-4360/14/12/2509>. Acesso em: 7 jul. 2025.

KHAN, M. A. et al. Application of gene expression programming (GEP) for the prediction of compressive strength of geopolymer concrete. **Materials**, [S.l.], 2021. Disponível em: <https://www.mdpi.com/1996-1944/14/5/1106>. Acesso em: 7 jul. 2025.

KHAN, M. A. et al. Geopolymer concrete compressive strength via artificial neural network, adaptive neuro fuzzy interface system, and gene expression programming with K-fold cross validation. **Frontiers in Materials**, [S.l.], 2021. Disponível em: <https://www.frontiersin.org/journals/materials/articles/10.3389/fmats.2021.621163/full>. Acesso em: 7 jul. 2025.

KONG, Y. K.; KURUMISAWA, K. Application of machine learning in predicting workability for alkali-activated materials. **Case Studies in Construction Materials**, [S.l.], 2023. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2214509523003534>. Acesso em: 7 jul. 2025.

LEONG, H. Y. et al. Effects of significant variables on compressive strength of soil-fly ash geopolymer: variable analytical approach based on neural networks and genetic programming. **Journal of Materials in Civil Engineering**, [S.l.], 2018. Disponível em: <https://ascelibrary.org/doi/10.1061/%28ASCE%29MT.1943-5533.0002246>. Acesso em: 7 jul. 2025.

LI, L. et al. Surface cracking and fractal characteristics of bending fractured polypropylene fiber-reinforced geopolymer mortar. **Fractal and Fractional**, [S.l.], 2021. Disponível em: <https://www.mdpi.com/2504-3110/5/4/142>. Acesso em: 7 jul. 2025.

LIPPMANN, R. An introduction to computing with neural nets. **IEEE ASSP Magazine**, [S.l.], p. 4-22, 1987. Disponível em: <https://ieeexplore.ieee.org/document/1165576>. Acesso em: 7 jul. 2025.

LOPES, C. de; MENDES, J. C. Ética e inteligência artificial. **Revista da UFMG**, Minas Gerais, v. 30, 2023. <https://periodicos.ufmg.br/index.php/revistadaufmg/article/view/47673>. Acesso em: 7 jul. 2025.

LOUATI, S.; BAKLOUTI, S.; SAMET, B. Acid based geopolymerization kinetics: effect of clay particle size. **Applied Clay Science**, [S.l.], 2016.

LOUATI, S.; BAKLOUTI, S.; SAMET, B. Geopolymers based on phosphoric acid and illito-kaolinitic clay. **Advances in Materials Science and Engineering**, [S.l.], 2016.

MAHAMAT, A. A. et al. Machine learning approaches for prediction of the compressive strength of alkali activated termite mound soil. **Applied Sciences**, [S.l.], 2021. Disponível em: <https://www.mdpi.com/2076-3417/11/11/4754>. Acesso em: 7 jul. 2025.

MANSOURI, E.; MANFREDI, M.; HU, J.-W. Environmentally friendly concrete compressive strength prediction using hybrid machine learning. **Sustainability**, Suíça, 2022. Disponível em: <https://www.mdpi.com/2071-1050/14/20/12990>. Acesso em: 7 jul. 2025.

MATHIVET, V. et al. Acid-based geopolymers: understanding of the structural evolutions during consolidation and after thermal treatments. **Journal of Non-Crystalline Solids**, [S.l.], v. 512, p. 90-97, 2019.

MEHO, L. I.; ROGERS, Y. Citation counting, citation ranking, and h-index of human-computer interaction researchers: a comparison of Scopus and Web of Science. *Journal of the American Society for Information Science and Technology*, [S.l.], p. 1.711-1.726, 2008. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/asi.20874>. Acesso em: 7 jul. 2025.

MURPHY, K. P. **Machine Learning: a Probabilistic Perspective**. Londres: Massachusetts Institute of Technology, 2012.

NAGARAJU, T. V. et al. Geopolymer-stabilized soils: influencing factors, strength development mechanism and sustainability. **Journal of Taibah University for Science**, [S.l.], 2023. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/16583655.2023.2248651>. Acesso em: 7 jul. 2025.

NAZAR, S. et al. Machine learning interpretable-prediction models to evaluate the slump and strength of fly ash-based geopolymer. **Journal of Materials Research and Technology**, [S.l.], 2023, p. 100–124. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2238785423004143>. Acesso em: 7 jul. 2025.

NGO, A. Q.; NGUYEN, L. Q.; TRAN, V. Q. Developing interpretable machine learning-shapley additive explanations model for unconfined compressive strength of cohesive soils stabilized. **PLOS ONE**, [S.l.], 2023. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0286950>. Acesso em: 7 jul. 2025.

PAIXÃO, R. C. et al. Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization. *IBRACON Structures and Materials Journal*, [S.l.], v. 15, n. 5, p. 1-17, 2022. Disponível em: <https://www.scielo.br/j/riem/a/5cnprbFfctmjGpnLnBkVtDS/?lang=en>. Acesso em: 7 jul. 2025.

PENG, Y.; UNLUER, C. Analyzing the mechanical performance of fly ash-based geopolymer concrete with different machine learning techniques. **Construction and Building Materials**, [S.l.], v. 316, 2022.

PENIDO, R. E.-K. et al. Predicting the compressive strength of steelmaking slag concrete with machine learning – Considerations on developing a mix design tool. **Construction and Building Materials**, [S.l.], 2022. DOI: <https://doi.org/10.1016/j.conbuildmat.2022.127896>.

PINTELAS, E. et al. A multi-view-CNN framework for deep representation learning in image classification. **Computer Vision and Image Understanding**, [S.l.], 2023. DOI: <https://doi.org/10.1016/j.cviu.2023.103687>.

RAHMAN, S. K.; AL-AMERI, R. Structural assessment of Basalt FRP reinforced self-compacting geopolymer concrete using artificial neural network (ANN) modelling. **Construction and Building Materials**, [S.l.], 2023. DOI: <https://doi.org/10.1016/j.conbuildmat.2023.132464>.

RISTIĆ, N. et al. Gaussian Regression Process for Prediction of Compressive Strength of Thermally Activated Geopolymer Mortars. **Tehnički vjesnik**, [S.l.], p. 1.833-1.840, 2022. DOI: <https://doi.org/10.17559/TV-20210925112341>.

SHEIATI, S.; BEHBOODI, S.; RANJBAR, N. Segmentation of backscattered electron images of geopolymers using convolutional autoencoder network. **Expert Systems with Applications**, [S.l.], 2022. DOI: <https://doi.org/10.1016/j.eswa.2022.117846>.

TANG, J. et al. Mechanical and microstructural properties of phosphate-based geopolymers with varying Si/Al molar ratios based on the sol-gel method. **Materials Letters**, [S.l.], v. 308, 2022.

TANG, Y. Z. et al. Artificial Neural Network-Forecasted Compression Strength of Alkaline-Activated Slag Concretes. *Sustainability*, Suíça, 2022. DOI: <https://doi.org/10.3390/su14095214>.

TANYILDIZI, H. Predicting the geopolymerization process of fly ash-based geopolymer using deep long short-term memory and machine learning. **Cement and Concrete Composites**, [S.l.], 2021. DOI: <https://doi.org/10.1016/j.cemconcomp.2021.104177>.

TARIQ, S.; HU, Z.; ZAYED, T. Micro-electromechanical systems-based technologies for leak detection and localization in water supply networks: A bibliometric and systematic review. **Journal of Cleaner Production**, [S.l.], 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0959652620357978?via%3Dihub>. Acesso em: 7 jul. 2025.

UPRETI, K. et al. Prediction of Mechanical Strength by Using an Artificial Neural Network and Random Forest Algorithm. **Journal of Nanomaterials**, [S.l.], 2022. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1155/2022/7791582>. Acesso em: 7 jul. 2025.

VÖLKER, C. et al. Sequential learning to accelerate discovery of alkali-activated binders. **Journal of Materials Science**, [S.l.], p. 15.859-15.881, 2021. Disponível em: <https://link.springer.com/article/10.1007/s10853-021-06324-z>. Acesso em: 7 jul. 2025.

WANG, Q. et al. Application of Soft Computing Techniques to Predict the Strength of Geopolymer Composites. **Polymers**, [S.l.], 2022. Disponível em: <https://www.mdpi.com/2073-4360/14/6/1074>. Acesso em: 7 jul. 2025.

WUNI, I. Y.; SHEN, G. Q.; OSEI-KYEI, R. Scientometric review of global research trends on green buildings in construction journals from 1992 to 2018. **Energy and Buildings**, [S.l.], p. 69-85, 2019. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378778818334571>. Acesso em: 7 jul. 2025.

XU, D. et al. Concrete and steel bridge Structural Health Monitoring—Insight into choices for machine learning applications. **Construction and Building Materials**, [S.l.], 2023. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0950061823023127>. Acesso em: 7 jul. 2025.

YASEEN, Z. M. et al. Shear strength prediction of steel fiber reinforced concrete beam using hybrid intelligence models: a new approach. **Engineering Structures**, [S.l.], p. 244-255, 2018.

ZEINI, H. A. et al. Random Forest Algorithm for the Strength Prediction of Geopolymer Stabilized Clayey Soil. Sustainability, Suíça, 2023. Disponível em: <https://www.mdpi.com/2071-1050/15/2/1408>. Acesso em: 7 jul. 2025.

ZOU, Y. et al. Evaluation of Artificial Intelligence Methods to Estimate the Compressive Strength of Geopolymers. **Gels**, [S.l.], 2022. Disponível em: <https://www.mdpi.com/2310-2861/8/5/271>. Acesso em: 7 jul. 2025.

3.8 Apêndice A

Tabela 2 – Trabalhos Detectados pela Metodologia

Título	Ano	Autores	Periódico
Effects of significant variables on compressive strength of soil-fly ash geopolymer: Variable analytical approach based on neural networks and genetic programming	2018	Leong, H. Y.; Ong, D. E. L.; Sanjayan, J. G.; Nazari, A.; Kueh, S. M.	Journal of Materials in Civil Engineering
Artificial intelligence approaches for prediction of compressive strength of geopolymer concrete	2019	Dao, D. V.; Ly, H. B.; Trinh, F. H.; Lee, T-T.; Pham, B. T.	Materials
Prediction of compressive strength of geopolymer concrete using entirely steel slag aggregates: Novel hybrid artificial intelligence approaches	2019	Dao, D. V.; Trnh, S. H.; Ly, G-B.; Pham, B. T.	Applied Sciences (Switzerland)
A machine learning-assisted numerical predictor for compressive strength of geopolymer concrete based on experimental data and sensitivity analysis	2020	Huynh, A. T.; Nguyen, Q. D.; Zuan, Q. L.; Magee, B.; Cgung, T.; Tran, K. T.; Nguyen, K. T.	Applied Sciences (Switzerland)
Estimating strength properties of geopolymer self-compacting concrete using machine learning techniques	2020	Awoyera, P. O; Kirgiz, M. S.; Viloria, A.; Ovallos-Gazabon, D.	Journal of Materials Research and Technology
Formulation of mix design for 3D printing of geopolymers: A machine learning approach	2020	Bagheri, A.; Cremona, C.	Materials Advances

Título	Ano	Autores	Periódico
Application of gene expression programming (GEP) for the prediction of compressive strength of geopolymer concrete	2021	Khan, M. A.; Zafar, A.; Akbar, A.; Javed, M. F.; Mosavi, A.	Materials
Bayesian regularized artificial neural network models to predict strength characteristics of fly-ash and bottom-ash based geopolymer concrete	2021	Aneja, S.; Sharma, A.; Gupta, R.; Yoo, D-Y.	Materials
Geopolymer Concrete Compressive Strength via Artificial Neural Network Adaptive Neuro Fuzzy Interface System and Gene Expression Programming With K-Fold Cross Validation	2021	Khan, M. A.; Zafar, A.; Farooq, F.; Javed, M. F.; Alyousef, R.; Alabduljabbar, H.; Khan, M. I.	Frontiers in Materials
Machine learning approaches for prediction of the compressive strength of alkali activated termite mound soil	2021	Mahamat, A. A.; Boukar, M. M.; Ibrahim, N. M.; Stanislas, T. T.; Bih, N. L.; Obianyo, I. I.; Jr, H. S.	Applied Sciences (Switzerland)
Machine learning to predict properties of fresh and hardened alkali-activated concrete	2021	Gomaa, E.; Han, T.; Elgawady, M.; Huang, J.; Kumar, A.	Cement and Concrete Composites
Novel analytical method for mix design and performance prediction of high calcium fly ash geopolymer concrete	2021	Gunasekara, C.; Atzarakis, P.; Lokuge, W.; Law, D. W.; Setunge, S.	Polymers
Prediction of geopolymer concrete compressive strength using novel machine learning algorithms	2021	Ahmad, A.; Ahmad, W.; Chaiyasarn, K.; Ostrowski, K. A.; Aslam, F.; Zajdel, P.; Joyklad, P.	Polymers
Sequential learning to accelerate discovery of alkali-activated binders	2021	Volker, C.; Firdous, R.; Stephan, D.; Kruschwitz, S.	Journal of Materials Science
Surface cracking and fractal characteristics of bending fractured polypropylene fiber-reinforced geopolymer mortar	2021	Li, L.; Sun, H-X.; Zhang, Y.; Yu, B.	Fractal and Fractional
Sustainable use of fly-ash: Use of gene-expression programming (GEP) and multi-expression programming (MEP) for forecasting the compressive strength geopolymer concrete	2021	Chu, H. H.; Khan, M. A.; Javed, M.; Zafar, A.; Khan, M. I.; Alabduljabbar, H.; Qayyum, S.	Ain Shams Engineering Journal
Analyzing the mechanical performance of fly ash-based geopolymer concrete with different machine learning techniques	2022	Peng, Y.; Unluer, C.	Construction and Building Materials
ANN based predictive mimicker for mechanical and rheological properties of eco-friendly geopolymer concrete	2022	Rehman, F.; Khokhar, S. A.; Kushnood, R. A.	Case Studies in Construction Materials
Application of Machine Learning Approaches to Predict the Strength Property of Geopolymer Concrete	2022	Cao, R.; Fang, Z.; Jin, M.; Shang, Y.	Materials
Application of non-parametric statistical methods to predict pumpability of geopolymers for well cementing	2022	Hamie, H.; Hoayek, A.; El-Ghoul, B.; Khalifeh, M.	Journal of Petroleum Science and Engineering
Application of Soft Computing Techniques to Predict the Strength of Geopolymer Composites	2022	Wang, Q.; Ahmad, W.; Ahmad, A.; Aslam, F.; Mohamed, A.; Vatin, N. I.	Polymers

Título	Ano	Autores	Periódico
Artificial Neural Network-Forecasted Compression Strength of Alkaline-Activated Slag Concretes	2022	Tang, Y. X.; Lee, Y. H.; Amran, M.; Fediuk, R.; Vatin, N.; Kueh, A. B. H.; Lee, Y. Y.	Sustainability (Switzerland)
Artificial Neural Network with a Cross-Validation Technique to Predict the Material Design of Eco-Friendly Engineered Geopolymer Composites	2022	Kuppusamy, Y.; Jayaseelan, R.; Pandulu, G.; Kumar, V. S.; Murali, G.; Dixit, S.; Vatin, N. I.	Materials
Assessment of Artificial Intelligence Strategies to Estimate the Strength of Geopolymer Composites and Influence of Input Parameters	2022	Khan, K.; Ahmad, W.; Amin, M. N.; Ahamad, A.; Nazar, S.; Al-Faiad, M. A.	Polymers
Compressive strength analysis of fly ash-based geopolymer concrete using machine learning approaches	2022	Emarah, D. A.	Results in Materials
Compressive Strength Estimation of Geopolymer Composites through Novel Computational Approaches	2022	Amin, M. N.; Khan, K.; Ahmad, W.; Javed, M. F.; Qureshi, H. J.; Saleem, M. U.; Qadir, M. G.; Faraz, M. I.	Polymers
Compressive strength prediction of fly ash-based geopolymer concrete via advanced machine learning techniques	2022	Ahmad, A.; Ahmad, W.; Aslam, F.; Joyklad, P.	Case Studies in Construction Materials
Environmentally Friendly Concrete Compressive Strength Prediction Using Hybrid Machine Learning	2022	Mansouri, E.; Maeve, M.; Hu, J-W.	Sustainability (Switzerland)
Evaluation of Artificial Intelligence Methods to Estimate the Compressive Strength of Geopolymers	2022	Zou, Y.; Zheng, C.; Alzahrani, A. M.; Ahmad, W.; Ahmad, A.; Mohamed, A. M.; Khallaf, R.; Elattar, S.	Gels
Gaussian Regression Process for Prediction of Compressive Strength of Thermally Activated Geopolymer Mortars	2022	Ristic, N.; Petrovic, E.; Bijeljic, J.; Simonovic, M.; Grdic, D.; Nikolic, V.; Grdic, Z.	Tehnicki Vjesnik
Predicting the Geopolymerization Process of Fly-Ash-Based Geopolymer Using Machine Learning	2022	Chen, K.; Cheng, Y.; Yu, M.; Liu, L.; Wang, Y.; Zhang, J.	Buildings
Prediction of Mechanical Properties of Fly-Ash/Slag-Based Geopolymer Concrete Using Ensemble and Non-Ensemble Machine-Learning Techniques	2022	Amin, M. N.; Khan, K.; Javed, M. F.; Aslam, F.; Qadir, M. G.; Faraz, M. I.	Materials
Prediction of Mechanical Strength by Using an Artificial Neural Network and Random Forest Algorithm	2022	Upreti, K.; Verma, M.; Agrawal, M.; Garg, J.; Kaushik, R.; Agrawal, C.; Singh, D.	Journal of Nanomaterials
Predictive Regression Models for the Compressive Strength of Fly Ash-based Alkali-Activated Cementitious Materials via Machine Learning	2022	Maddad, H. A.; Kheimi, M.; El-Wafa, M. A.	Engineering, Technology & Applied Science Research
Segmentation of backscattered electron images of geopolymers using convolutional autoencoder network	2022	Sheiati, S.; Behboodi, S.; Ranjbar, N.	Expert Systems with Applications

Título	Ano	Autores	Periódico
Statistical Methods for Modeling the Compressive Strength of Geopolymer Mortar	2022	Ahmed, H. U.; Abdalla, A. A.; Mohammed, A. S.; Mohammed, A. A.; Mosavi, A.	Materials
The Length Change Ratio of Ground Granulated Blast Furnace Slag-Based Geopolymer Blended with Magnesium Oxide Cured in Various Environments	2022	Chen, Y-C.; Lee, W-H.; Cheng, T-W.; Chen, W.; Li, Y-F.	Polymers
A machine learning model to predict unconfined compressive strength of alkali-activated slag-based cemented paste backfill	2023	Arachchilage, C. B.; Fan, C.; Zhao, J.; Huang, G.; Liu, W. V.	Journal of Rock Mechanics and Geotechnical Engineering
A Novel MBAS-RF Approach to Predict Mechanical Properties of Geopolymer-Based Compositions	2023	Chen, S.; Zhou, M.; Shi, X.; Huang, J.	Gels
Application of machine learning in predicting workability for alkali-activated materials	2023	Kong, Y. K.; Kurumisawa, K.	Case Studies in Construction Materials
Data driven design of alkali-activated concrete using sequential learning	2023	Völker, C.; Torres, B. M.; Rug, T.; Firdous, R.; Zia, G. A. J.; Lüders, S.; Scaffino, H. L.; Höppler, M.; Böhmer, F.; Pfaff, M.; Stephan, D.; Kruschwitz, S.	Journal of Cleaner Production
Developing interpretable machine learning-shapley additive explanations model for unconfined compressive strength of cohesive soils stabilized	2023	Ngo, A. Q.; Nguyen, L. Q.; Tran, V. Q.	PLoS ONE
Effect of combined different sources of alumina silicate on mechanical properties and carbonation depth of environmentally friendly geopolymeric composite based on metakaolin	2023	Espahman, A.; Mehrdadi, N.	International Journal of Engineering, Transactions B: Applications
Geopolymer-stabilized soils: influencing factors, strength development mechanism and sustainability	2023	Nagaraju, T. C.; Mantena, S.; Gobinath, R. Bonthu, S.; Alisha, S. S.	Journal of Taibah University for Science
Machine learning interpretable-prediction models to evaluate the slump and strength of fly ash-based geopolymer	2023	Nazar, S.; Yang, J.; Amin, M. N.; Khan, K.; Ashraf, M.; Aslam, F.; Javed, M. F.; Eldin, S. M.	Journal of Materials Research and Technology
Prediction of geopolymer pumpability and setting time for well zonal isolation - Using machine learning and statistical based models	2023	Hoayek, A.; Khalifeh, M.; Hamie, H.; El-Ghoul, B.; Zogheib, R.	Heliyon
Random Forest Algorithm for the Strength Prediction of Geopolymer Stabilized Clayey Soil	2023	Zeini, H. A.; Al-Jeznawi, D.; Imran, H.; Bernardo, L. F. A.; Al-Khafaji, Z.; Ostrowski, K. A.	Sustainability (Switzerland)
Structural assessment of Basalt FRP reinforced self-compacting geopolymer concrete using artificial neural network (ANN) modelling	2023	Rahman, S. K.; Al-Ameri, R.	Construction and Building Materials

Fonte: Autores.

3.9 Sobre os(as) autores(as)

Aldo Ribeiro de Carvalho é professor no Instituto Federal do Sudeste de Minas Gerais (IF Sudeste MG), Campus Juiz de Fora, no núcleo de Construção Civil, e doutorando em Engenharia Civil na Universidade Federal de Ouro Preto (PROPEC/UFOP). Atualmente é membro do Ative-CNPq - Grupo de Pesquisas de Cimentos Álcali-Ativados e Ácidos-Ativados e do CIDENG-CNPq - Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia. Possui especializações em Docência no Ensino Superior, Engenharia de Segurança do Trabalho e em Gestão Pública em Defesa Civil. Tem experiências em patologias das construções, compósitos cimentícios, compósitos geopoliméricos ácidos e alcalinos, reaproveitamento de resíduos e aplicações de nanomateriais em materiais de construção.

Romário Parreira Pita é mestre em Engenharia Civil na área de concentração de Materiais e Construção pelo Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Ouro Preto (PROPEC/UFOP). Possui especializações em Sustentabilidade na Construção Civil e Engenharia de Segurança do Trabalho. Tem experiências em patologias das construções, certificações de sustentabilidade para edificações e aprendizagem de máquina aplicada ao mercado imobiliário.

Thaís Mayra de Oliveira é professora associada do curso de Engenharia Civil e do Programa de Pós-Graduação em Engenharia Civil (PEC) da Universidade Federal de Juiz de Fora (UFJF). Coordenadora do Laboratório de Materiais de Construção (LMCC/UFJF) da Faculdade de Engenharia da UFJF. Sua pesquisa tem ênfase em materiais e componentes de construção, nanomateriais em matrizes cimentícias, ensaios não-destrutivos e destrutivos, termomecânica em concretos, concretos permeáveis, e reaproveitamento de resíduos.

Guilherme Jorge Brigolini Silva é professor associado da Universidade Federal de Ouro Preto (UFOP) e professor no programa de Pós-Graduação em Engenharia Civil (PROPEC) em Engenharia das Construções (MECON). Coordenador do Grupo de Pesquisas ATIVE - CNPq. Coordenador do Laboratório de Construção Civil – LCC/UFOP. Tem experiência na área de Engenharia de Materiais, com ênfase em materiais cerâmicos, cimento Portland, cimentos alcalino-ativados, aproveitamento de resíduos, atividade pozzolânica e processos construtivos.

Júlia Castro Mendes é professora na Universidade Federal de Juiz de Fora (UFJF) e docente Permanente dos Programas de Pós-Graduação em Engenharia Civil da UFOP (PROPEC/UFOP) e da UFJF (PEC/UFJF). Coordenadora do CIDENG-CNPq - Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia. Representante brasileira da WREN - Women's Research Engineers Network. Tem experiência na área de aprendizagem de máquina aplicada à materiais de construção, materiais e técnicas de construção sustentáveis, reaproveitamento de resíduos sólidos, propriedades térmicas de matrizes cimentícias e eficiência energética em edificações.

4 INFLUÊNCIA DA HETEROGENEIDADE DOS BANCOS DE DADOS NA DOSAGEM DE CONCRETOS POR MEIO DE APRENDIZADO DE MÁQUINA

Breno Soares Pinheiro¹, Alexandre Abrahão Cury², Júlia Castro Mendes³

¹ Universidade Federal de Juiz de Fora.

² Departamento de Mecânica Aplicada, Universidade Federal de Juiz de Fora.

³ Departamento de Construção Civil, Universidade Federal de Juiz de Fora.

4.1 Resumo

As metodologias atuais de dosagem de concretos são métodos empíricos, baseadas em gráficos, tabelas e correlações analíticas. Nos últimos anos, ferramentas de Aprendizado de Máquina têm sido aplicadas para aumentar a eficiência desse processo, permitindo predições autônomas. No entanto, a variabilidade dos componentes do concreto (ex.: tipos de cimento, moldagem dos corpos de prova, diferentes tamanhos e origem dos agregados, entre outros) ainda representa um desafio. Assim, este trabalho avalia a influência da heterogeneidade dos dados na predição da resistência à compressão de traços de concreto. Foram coletados dados de três Instituições de Ensino Superior situadas na mesma macrorregião geológica: UFJF, UFOP e UFV. Após o pré-processamento, os bancos de dados e suas combinações foram testados com o algoritmo XGBoost para prever a resistência à compressão. A acurácia foi avaliada por validação cruzada (k -fold = 10) e através de três métricas: R^2 , MAE e RMSE. Os modelos apresentaram R^2 entre 0,34 e 0,84, e MAE de 2,62 a 4,82 MPa. O menor banco de dados (31 instâncias) resultou nos piores desempenhos, com dados insuficientes para o processo de aprendizado do modelo. Já o melhor modelo, a alta similaridade dos dados gerou *overfitting*. As combinações entre os bancos de dados não indicaram tendências claras de melhoria. Assim, os dados utilizados foram insuficientes para cumprir os objetivos do estudo, mas proporcionaram aprendizados sobre a qualidade dos modelos de Aprendizado de Máquina.

Palavras-Chave: Capacidade de generalização; Banco de dados de concreto; Aprendizado de Máquina; Dosagem de concretos; Resistência à compressão

4.2 Introdução

O concreto é o principal elemento da construção civil e um dos materiais mais utilizados no mundo. A resistência à compressão do concreto é uma das propriedades mais importantes do material, medida a partir de ensaios de ruptura aos 28 dias, condição de suficiente hidratação da matriz cimentícia (Ni; Wang, 2000).

Existem diversos métodos de dosagem, como aqueles desenvolvidos pela American Concrete Institute (ACI), pela Associação Brasileira de Cimento Portland (ABCP) e pelo Instituto Brasileiro de Pesquisas Tecnológicas (IPT). A partir de baterias de ensaios, é possível determinar equações empíricas ou correlações gráficas de consumo de cada material para se obter uma determinada faixa de resistência de interesse. Essas técnicas de dosagem normalmente envolvem avaliações e correções iterativas, demandando recursos naturais para confecção dos corpos de prova e tempo para que os testes sejam realizados na data correta.

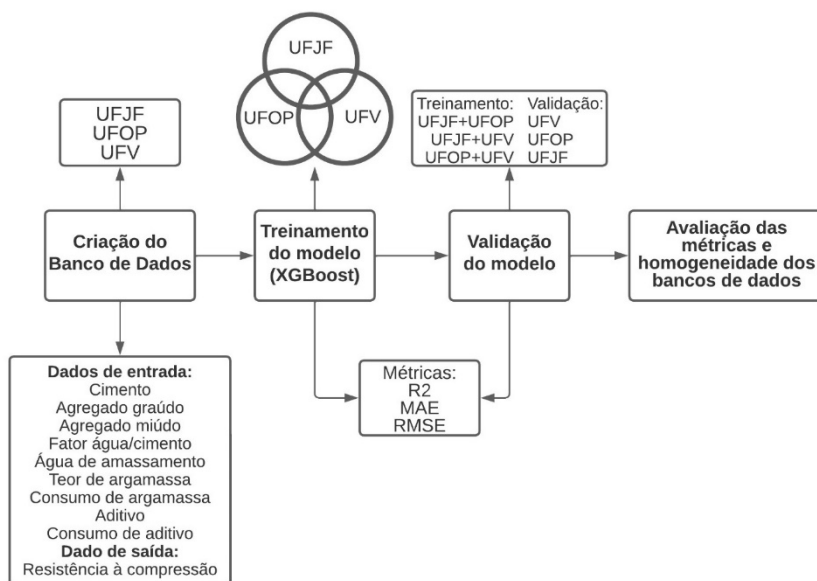
Dada a complexidade do problema, há estudos que visam desenvolver uma ferramenta mais eficiente e acurada para a definição do traço de concreto e que possa contribuir para aumentar a segurança das edificações, além de reduzir gastos materiais e de tempo representados pela necessidade de testes experimentais (Zhao; Hu; Song; Wang, 2022). O uso do Aprendizado de Máquina possibilita a determinação dos traços de concreto para uma dada resistência de maneira mais eficaz, alcançando erros baixos, acelerando a dosagem e economizando recursos gastos no método empírico de determinação (Paixão et al., 2022; Moein et al., 2023).

A partir de estudos anteriores, a homogeneidade dos bancos de dados utilizados nesse processo representa um ponto de pesquisa muito pouco estudado. Assim, diversos questionamentos são levantados: apesar de adequado para estimar valores dentro da sua base de dados de treinamento, é possível que modelos de aprendizado de máquina possam generalizar outros dados? Como a quantidade e qualidade do banco de dados pode influenciar a acurácia da predição?

Nesse sentido, esse trabalho investiga a influência da heterogeneidade do banco de dados nos resultados de modelos de aprendizado de máquina para dosagem de concretos. Além disso, busca-se analisar o processo de *Transfer Learning*, através do qual podemos analisar a capacidade de generalização dos modelos.

4.3 Metodologia

Figura 1 – Fluxograma da metodologia



Fonte: Autores.

Inicialmente foi criado um banco de dados a partir de traços de concreto comuns obtidos de três universidades brasileiras: UFJF, UFOP e UFV, situadas em regiões de geologia similar e com os mesmos tipos de rochas como agregados, o gnaiss. Porém, os métodos de dosagem utilizados variam entre o ABCP, o IPT e ainda adaptações desses métodos. A variação do método utilizado por cada instituição representa ainda uma grande heterogeneidade entre os dados, visto que cada método possui suas próprias particularidades na definição do traço.

A pesquisa por artigos e trabalhos foi feita através do *Google Acadêmico* e através do Currículo *Lattes* dos professores das três instituições. A pesquisa se destinou a buscar traços de concreto comuns com resistências à compressão variando de 15 a 50 MPa e sem adições. Foram recolhidas informações como a composição do traço (cimento, agregados e água), o consumo de cimento e o tipo, massas específicas dos materiais, consumo de aditivos, dimensões e idade dos corpos de prova no rompimento e resistência à compressão. Posteriormente, esse banco de dados foi subdividido em sete diferentes conjuntos: UFJF (39); UFOP (51); UFV (31); UFJF+UFOP (90); UFJF+UFV (70); UFOP+UFV (82); e, UFJF+UFOP+UFV (121).

Após a consolidação e o pré-processamento dos dados, um modelo baseado em Aprendizado de Máquina foi treinado – XGBoost. Este é um algoritmo baseado em árvore de decisão, onde em cada nó há uma decisão que divide o banco de dados em conjuntos menores com características semelhantes (Rezende, 2003). A escolha por esse algoritmo se deu devido a boa performance em estudos analisados anteriormente e o baixo custo computacional.

A pesquisa utilizou a validação cruzada (*k-fold*), em que consiste em dividir o banco de dados de forma aleatória em “k” subconjuntos, assim o algoritmo usa “k-1” subconjuntos para treinar o modelo e o último subconjunto para testá-lo (Kohavi, 1995). Esse processo se repete por “k” vezes até que todos os subconjuntos sejam utilizados como teste. Definiu-se o número de pastas k=10.

A qualidade das predições foi avaliada a partir de três métricas: coeficiente de determinação (R^2), erro médio absoluto (MAE) e raiz quadrática média dos erros (RMSE). Posteriormente, o processo de *transfer learning* buscou analisar a generalização dos modelos, utilizando um banco de dados para treinamento e outro para validação. Novamente, usou-se as três métricas quantitativas.

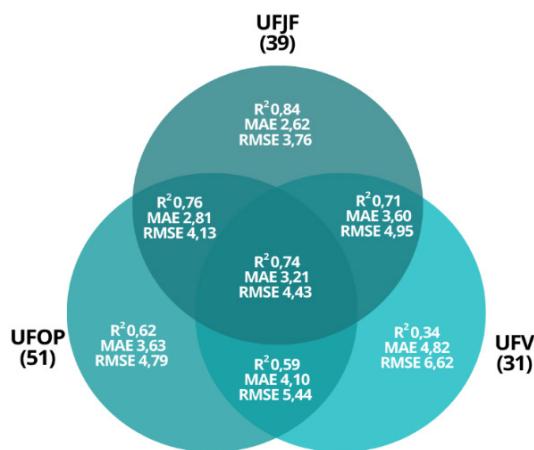
Todas as simulações foram feitas em um computador com processador *Intel Core i5-8265* com 16GB de RAM. Os algoritmos utilizados foram implementados na plataforma *Google Colaboratory* com as bibliotecas *Pandas*, *Scikit-Learn*, *XGBoost* e *TensorFlow*. O repositório contendo o código utilizado e as bases de dados estão disponíveis em: <https://github.com/brenospinheiro/ML-e-concreto.git>.

4.4 Resultados

4.4.1 Avaliação dos bancos de dados de cada instituição

Os resultados dos modelos otimizados e validados de forma cruzada são mostrados na Figura 2, para cada conjunto e combinação de bancos de dados.

Figura 2 – Métricas para cada modelo. Nota: MAE e RMSE MPa



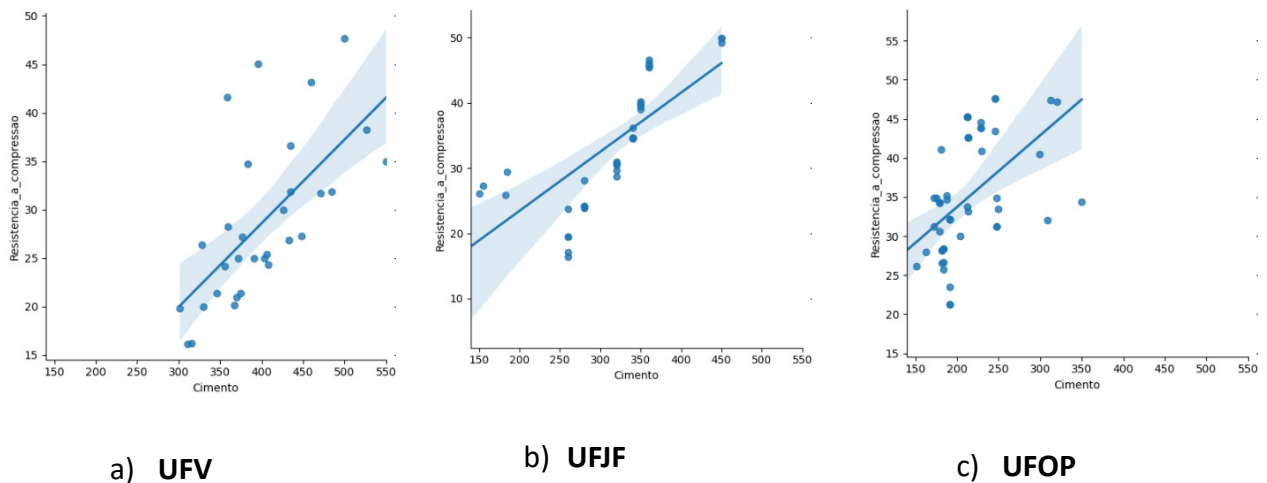
Fonte: Autores.

O modelo treinado com o banco de dados da UFJF alcançou um R^2 de 0,84, o que aparentemente indica um bom resultado na predição da resistência pelo modelo. Além disso, o modelo apresentou o melhor resultado para as métricas MAE e RMSE: 2,62 e 3,76 MPa, respectivamente. Por outro lado, o modelo treinado com o banco de dados da UFV apresentou o pior rendimento nas três métricas, com o R^2 igual a

0,34, 60% inferior ao resultado encontrado no modelo UFJF. O MAE e RMSE foram igualmente piores - 180% e 176% superiores aos da UFJF, respectivamente. O modelo treinado com o banco de dados da UFOP obteve um resultado intermediário entre os dois citados anteriormente. Por mais que ele represente mais que 40% do total de dados coletados, apresentou R^2 igual a 0,62 e valores de MAE e RMSE iguais a 3,63 e 4,79 MPa, respectivamente.

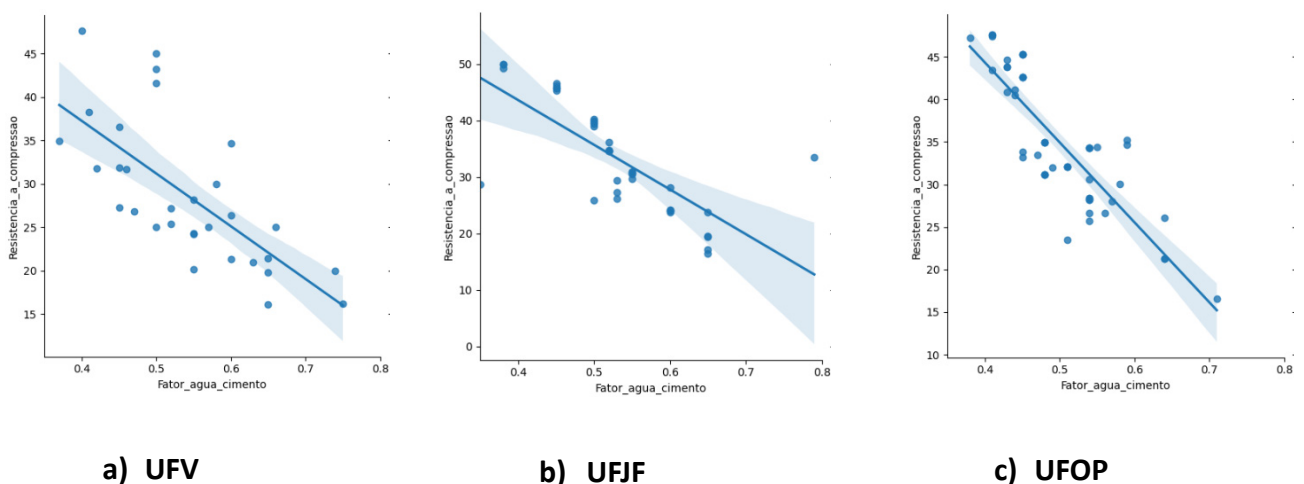
O desempenho dos modelos deste trabalho, especialmente o da UFV, sofreu consequências do reduzido número de amostras quando comparado a outros trabalhos, que possuem centenas de instâncias. Além disso, o baixo desempenho dos modelos da UFV e da UFOP também pode ter sido resultado da variabilidade dos dados contidos em cada banco de dados.

Figura 3 – Resistência a compressão x consumo de cimento



Fonte: Autor.

Figura 4 – Resistência a compressão x fator água/cimento.



Fonte: Autor.

Ao analisar o banco de dados da UFJF (39 instâncias), é possível verificar que, tanto no consumo de cimento (Figura 3, b) quanto no fator água/cimento (Figura 4, b),

existem pontos muito próximos. Essa baixa variação dos dados ao redor da reta de tendência e maior concentração dos traços foi capaz de trazer as melhores métricas para a UFJF. Esse resultado pode ser considerado um *overfitting*, onde as instâncias testadas eram semelhantes às usadas para treinamento, levando o modelo a um R^2 falsamente alto. Em outras palavras, temos a impressão de que o modelo entendeu bem a correlação entre os dados (alto R^2), mas na verdade ele está somente repetindo valores próximos aos usados no treinamento, não sendo capaz de avaliar dados diferentes daquela faixa bem representada. Como apresentado por Li et al. (2022), a dificuldade em criar bancos de dados suficientemente e variados e representativos aumenta o risco de ocorrer *overfitting*.

Em contrapartida, os dados da UFV apresentam maior variação dos traços. A maior variabilidade dos dados ajuda o modelo a generalizar e compreender as correlações entre as variáveis em diversas situações ao treinar o modelo com diferentes traços. Essa característica traz confiabilidade às métricas apresentadas. Porém, a quantidade de instâncias presentes no conjunto para treinamento é limitada, apenas 31 traços. Ou seja, há poucos dados para treinamento do algoritmo em cada faixa de variação, levando o modelo a ter o pior resultado.

O modelo UFOP apresentou resultado intermediário entre as métricas dos outros dois modelos. Diferentemente do modelo da UFJF que sofreu *overfitting*, o modelo UFOP não apresenta variação dos dados tão concentrada. Por mais que a faixa de variação ainda seja pequena, os dados encontram-se mais bem distribuídos, principalmente o fator água/cimento (Figura 4, c). Por mais que esse modelo não seja tão influenciado pelas consequências da concentração de dados, 51 traços ainda foram insuficientes para criar um modelo com boa acurácia (dada por $R^2 > 0,90$ nesta área).

4.4.2 Avaliação dos modelos com as combinações dos bancos de dados

Ao criarmos bancos de dados formados pela união de dois ou três bancos de dados iniciais, criamos modelos que são treinados com maior representatividade devido ao aumento do número de observações e da faixa de variação dos dados. Se no modelo somente da UFOP o consumo de cimento variava de 150 a 350 kg/m³, no modelo UFJF+UFOP+UFV essa variação é de 150 a 550 kg/m³. Além disso, a combinação dos 3 bancos de dados soma 121 instâncias, tamanho quase quatro vezes maior do que o banco de dados da UFV que continha apenas 31 traços.

Por outro lado, amplia-se a janela de variabilidade (heterogeneidade) entre os principais componentes de cada região e métodos de dosagem. Como apresentado por (Boggio, 2000), a diferença do consumo de cimento entre diferentes modelos

de dosagem pode ser significativa e, como o método de dosagem dos traços não foi acessado, pode representar uma heterogeneidade.

Tabela 1 – Relação entre os resultados dos modelos individuais e respectivas combinações

	Número de Instâncias	R ² obtido pelo modelo combinado	Média Aritmética do R ² dos individuais	Média Ponderada do R ² dos individuais
UFJF	39	0,84	-	-
UFOP	51	0,62	-	-
UFV	31	0,34	-	-
UFJF + UFOP	90	0,76	0,73	0,72
UFJF + UFV	70	0,71	0,59	0,62
UFOP + UFV	82	0,59	0,48	0,51
UFJF + UFOP + UFV	121	0,74	0,69	0,62

Fonte: Autores.

Os modelos que combinaram bancos de dados de duas instituições obtiveram resultados intermediários aos modelos das instituições isoladamente, embora superiores à média aritmética e à média ponderada dos R² isoladamente (Tabela 1), o que é positivo. Isso indica que o aumento do número de instâncias permitiu a todos os modelos um melhor entendimento dos padrões de correlação entre os componentes do concreto. Entretanto, os valores ainda não são tão altos quanto a literatura (devido à limitação dos bancos de dados) e ainda sofrem efeitos do *overfitting* do banco de dados da UFJF.

4.4.3 Análise da correlação entre as variáveis

A Tabela 2 foi criada com os resultados das matrizes de correlação para cada banco de dados e retrata a importância de cada variável em relação a resistência à compressão, obtida pela ferramenta nativa do XGBoost.

Tabela 2 – Matriz de correlação da importância de cada variável para a resistência a compressão

Modelos (R²)	UFJF (0,84)	UFOP (0,62)	UFV (0,34)	UFJF+ UFOP (0,76)	UFJF+ UFV (0,71)	UFOP+ UFV (0,59)	UFJF+UFOP+UFV (0,74)
Cimento (kg/m ³)	0,72	0,53	0,65	0,44	0,42	-0,04	0,17
Agregado miúdo (kg/m ³)	0,04	-0,07	-0,65	-0,06	-0,09	-0,44	-0,20
Agregado graúdo (kg/m ³)	0,22	-0,02	0,42	-0,02	0,13	-0,31	-0,14
Fator água/cimento (kg/kg)	-0,74	-0,85	-0,70	-0,79	-0,71	-0,78	-0,77
Água de amassamento (%)	0,20	-0,04	-0,28	-0,01	-0,15	-0,38	-0,23
Teor de argamassa (%)	-0,08	0,12	-0,61	0,03	-0,13	0,12	0,02
Aditivo (%)	0,22	0,09	-0,32	0,12	0,29	0,20	0,21
Consumo de aditivo (kg/m ³)	0,43	0,17	-0,32	0,24	0,41	0,26	0,29
Consumo de argamassa (kg/m ³)	0,48	0,54	0,32	0,42	0,26	-0,03	0,17

Fonte: Autores.

De maneira geral, o fator água/cimento se apresenta como a variável mais importante em todos os bancos de dados, que já era esperado. Porém, o consumo de cimento, que possui grande importância para a resistência, e as demais variáveis sofrem grande alteração na ordem de maior importância nos diferentes bancos de dados. Essa tendência indica que o banco de dados, possivelmente, não tem qualidade e representatividade suficiente para fazer com que o modelo compreenda as correlações reais entre os componentes do concreto.

A Tabela 3 mostra a ocorrência dos erros MAE para cada modelo. Por mais que apresentem valores de MAE mínimos muito baixos, alguns valores de MAE máximos são notórios. Como os bancos de dados possuem poucas instâncias e, em alguns casos, muita variação dos dados, isso faz com que o modelo ocasionalmente seja validado com um traço que não é representado no treinamento.

Tabela 3 – Ocorrência dos desvios para cada modelo

Modelo	Erro mínimo (MPa)	25% (MPa)	50% (mediana) (MPa)	75% (MPa)	Erro máximo (MPa)
UFJF	0,04	0,66	1,53	3,88	10,50
UFOP	0,07	1,26	2,35	6,09	14,59
UFV	0,33	1,44	3,35	5,87	14,90
UFJF + UFOP	0,02	0,74	1,87	3,98	15,93

Modelo	Erro mínimo (MPa)	25% (MPa)	50% (mediana) (MPa)	75% (MPa)	Erro máximo (MPa)
UFJF + UFV	0,03	0,77	2,53	5,70	13,52
UFOP + UFV	0,08	1,19	3,28	5,84	13,10
UFJF+UFOP+UFV	0,01	1,02	2,09	4,27	15,90

Fonte: Autores.

O modelo UFJF+UFOP, que se apresentou como o melhor modelo dentre as combinações feitas, possui 75% dos erros abaixo de 4,00 MPa. A análise desses desvios nos ajuda a verificar a capacidade da implementação do algoritmo em aplicações reais. A NBR 12655 (ABNT, 2022) fornece valores de desvio-padrão da resistência em função da condição de preparo do concreto sem experimentos prévios. O desvio-padrão recomendado pela norma na dosagem de concretos pode chegar em até 7 MPa a depender de como foi realizada a dosagem dos materiais em campo. Ao comparar o desvio-padrão da norma com os desvios apresentados na Tabela 3, pode-se verificar que em pelo menos 75% dos casos os erros encontrados pelos modelos são comparáveis com os erros esperados em processos de dosagem em campo. Assim, por mais que também existam erros máximos exorbitantes, que inviabilizariam a aplicação prática dos modelos de aprendizado de máquina, em sua maioria os valores estão promissores, e a criação de bancos de dados maiores e mais representativos poderia aumentar ainda mais a acurácia e realismo dos modelos.

4.4.4 Avaliação do *Transfer Learning*

Nesta etapa, um banco de dados foi utilizado para treinamento do algoritmo e outro diferente foi usado para validação. Essa técnica permite analisar se é possível aproveitar um modelo já treinado com certos dados para prever dados de outras fontes. A Tabela 4 apresenta os resultados obtidos.

Tabela 4 – Métricas para o processo de *Transfer Learning*

Treinamento	Validação	R ²	RMSE (MPa)	MAE (MPa)	Erro máximo (MPa)	Erro mínimo (MPa)
UFJF+UFOP	UFV	-0,77	10,89	9,64	20,51	1,13
UFJF+UFV	UFOP	-0,05	7,92	6,25	17,46	0,02
UFOP+UFV	UFJF	0,65	5,54	4,21	14,42	0,02
UFJF	UFOP	-0,67	9,97	8,11	18,70	0,34
UFJF	UFV	-3,43	17,22	15,51	27,51	0,76
UFOP	UFJF	0,57	6,17	5,14	16,33	0,13
UFOP	UFV	-0,24	9,10	8,40	16,00	1,96
UFV	UFJF	-0,02	9,48	8,08	16,78	0,08
UFV	UFOP	-0,06	7,96	6,20	15,67	0,03

Fonte: Autores.

Ao analisar os resultados obtidos, constata-se que apenas o modelo treinado com UFOP+UFV e validado com UFJF obteve R^2 próximo aos resultados dos modelos individuais, assumindo valor de 0,65. Porém, os valores de RMSE e MAE indicam uma diminuição da qualidade das previsões. Os piores resultados possuem os dados da UFJF no treinamento, sejam combinados ou não. Esse aspecto é uma consequência do *overfitting* desse modelo. O modelo falha ao prever valores para novos dados distintos das repetidas representações presentes no banco de dados.

De maneira geral, os resultados não foram satisfatórios, obtendo R^2 baixos e até mesmo negativos, que indicam que a previsão do modelo foi pior do que simplesmente adotar a média aritmética das instâncias. Esses resultados indicam a baixa capacidade de generalização dos modelos, ou seja, o modelo não é capaz de fazer previsões de instâncias diferentes da situação encontrada no banco de dados de treinamento.

4.5 Considerações Finais

A etapa de treinamento e teste utilizando a validação cruzada mostrou uma grande variabilidade de resultados, com R^2 entre 0,34 e 0,84. O pior modelo foi o modelo UFV que teve a baixa acurácia atribuída ao limitado número de instâncias (apenas 31), trazendo dificuldade no processo de treinamento. Já o melhor R^2 foi apresentado pelo modelo UFJF (com 39 instâncias). Entretanto, foi possível verificar que esse bom resultado foi consequência de um *overfitting*.

Na segunda etapa, quando os bancos de dados foram utilizados em conjunto e ainda validados com validação cruzada, as métricas de qualidade dos modelos combinados obtiveram valores intermediários aos obtidos individualmente, e superiores à média dos valores de cada modelo componente. A junção dos dados permitiu mitigar os efeitos do *overfitting* e ainda aumentar substancialmente o número de instâncias ao comparar os modelos individuais.

As diferenças entre os bancos de dados afetaram tanto o treinamento e validação dos modelos combinados quanto o *transfer learning*. O melhor resultado ocorreu com UFOP+UFV para treino e UFJF para validação, mas a alta dispersão dos dados prejudicou o desempenho. Modelos treinados com UFJF apresentaram R^2 negativo devido ao *overfitting*. No geral, os modelos não conseguiram fazer boas previsões com bancos distintos dos usados no treinamento, evidenciando que a limitação de dados dificultou a transferência das correlações aprendidas.

4.6 Agradecimentos

Os autores agradecem o apoio financeiro das agências de fomento CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior); CNPq (Conselho

Nacional de Desenvolvimento Científico e Tecnológico), FINEP (Financiadora de Estudos e Projetos) e FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais). Também agradecemos a colaboração do Grupo de Pesquisa em Ciência de Dados Aplicada à Engenharia (CIDENG-CNPq).

4.7 Referências

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. NBR 12655: Concreto de cimento Portland – Preparo, controle, recebimento e aceitação – Procedimento. Rio de Janeiro, 2022.

BOGGIO, A. J. **Estudo comparativo de métodos de dosagem de concretos de cimento Portland**. 2000. Disponível em: <http://hdl.handle.net/10183/12575>. Acesso em: 7 jul. 2025.

KOHAVI, R. A study of cross-validation and bootstraps for accuracy estimation and model selection. In: INTERNATIONAL JOIN CONFERENCE ON ARTIFICIAL INTELLIGENCE, 1995. Disponível em: https://www.researchgate.net/profile/Ron-Kohavi/publication/2352264_A_Study_of_Cross-Validation_and_Bootstrap_for_Accuracy_Estimation_and_Model_Selection. Acesso em: 7 jul. 2025.

LI, Z. et al. Machine learning in concrete science: applications, challenges, and best practices. **Computational Materials**, [S.l.], v. 8, 2022. Disponível em: <https://www.nature.com/articles/s41524-022-00810-x>. Acesso em: 7 jul. 2025.

MOEIN, M. M. et al. Predictive models for concrete properties using machine learning and deep learning approaches: A review. **Journal of Building Engineering**, [S.l.], v. 63, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352710222014504>. Acesso em: 7 jul. 2025.

NI, H.-G.; WANG, J.-Z. Prediction of compressive strength of concrete by neural networks. **Cement and Concrete Research**, [S.l.], v. 30, n. 8, 2000. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0008884600003458?via%3Dihub>. Acesso em: 7 jul. 2025.

PAIXÃO, R. C. et al. Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization. **IBRACON Structures and Materials Journal**, [S.l.], v. 15, 2022. Disponível em: https://www.researchgate.net/publication/359131100_Comparison_of_machine_learning_techniques_to_predict_the_compressive_strength_of_concrete_and_considerations_on_model_generalization. Acesso em: 7 jul. 2025.

REZENDE, S. O. **Sistemas inteligentes**: fundamentos e aplicações. Barueri: Manole, 2003. Disponível em: https://books.google.com.br/books?id=UsJe_PlbnWcC. Acesso em: 7 jul. 2025.

ZHAO, Y. et al. Predicting compressive strength of manufactured-sand concrete using conventional and metaheuristic-tuned artificial neural network. **Measurement**, [S.l.], 2022. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0263224122002664>. Acesso em: 7 jul. 2025.

4.8 Sobre os(as) autores(as)

Alexandre Abrahão Cury é Engenheiro Civil pela UFJF, mestre em Modelagem Computacional pela mesma instituição e doutor em Engenharia Civil pela École Nationale des Ponts et Chaussées. Suas pesquisas abordam monitoramento de integridade estrutural, machine learning e confiabilidade estrutural. Foi coordenador do PPG em Engenharia Civil da UFJF e membro da Câmara de Assessoramento de Arquitetura e Engenharias da FAPEMIG e da Comissão de Avaliação das Engenharias I da CAPES (2017-2021). É pesquisador de Produtividade do CNPq desde 2013, membro do Comitê de Assessoramento do CNPq e editor de Build Engineering e Structural Sensing.

Breno Pinheiro é engenheiro civil formado pela Universidade Federal de Juiz de Fora (UFJF). Durante a graduação foi membro do Programa de Educação Tutorial em Engenharia Civil (PET Civil) e do grupo de Ciência de Dados Aplicado à Engenharia (CIDENG), onde desenvolveu pesquisa envolvendo Aprendizado de Máquinas e predição da resistência de corpos de prova de concretos, assim como a avaliação da influência dos bancos de dados nas predições. Atualmente, atua no campo da Engenharia Estrutural. Seu interesse inclui Inteligência Artificial, assim como a área de concreto armado, estruturas metálicas e manifestações patológicas em estruturas.

Júlia Castro Mendes é professora na Universidade Federal de Juiz de Fora (UFJF) e docente Permanente dos Programas de Pós-Graduação em Engenharia Civil da UFOP (PROPEC/UFOP) e da UFJF (PEC/UFJF). Coordenadora do CIDENG-CNPq - Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia. Representante brasileira da WREN - Women's Research Engineers Network. Tem experiência na área de aprendizagem de máquina aplicada à materiais de construção, materiais e técnicas de construção sustentáveis, reaproveitamento de resíduos sólidos, propriedades térmicas de matrizes cimentícias e eficiência energética em edificações.

5 PROCESSAMENTO DE IMAGENS APLICADO AO MONITORAMENTO DE INTEGRIDADE ESTRUTURAL

Nalberth Vicentin Santana¹, Caroline Aparecida Ferreira¹, Cláudia Márcia Canazart¹

¹Programa de Pós-graduação em Engenharia Civil, Universidade Federal de Ouro Preto.

5.1 Resumo

Com o tempo, as estruturas estão sujeitas a desgastes causados por esforços e intempéries, o que pode levar à deterioração. Para evitar problemas graves, como o colapso de estruturas, é essencial realizar inspeções regulares e aplicar técnicas de monitoramento contínuo, essencial para identificar patologias em estágios iniciais e aplicar medidas corretivas, minimizando os custos de manutenção. A Inteligência Artificial, especialmente as Redes Neurais Convolucionais, tem se mostrado uma ferramenta eficiente nesse campo, facilitando o trabalho no segmento da engenharia diagnóstica e reduzindo a subjetividade da avaliação. Essas redes são capazes de identificar danos estruturais, como fissuras, corrosão e outros por meio do processamento de imagens. Outras técnicas de processamento de imagens, incluindo filtros para redução de ruído e outros algoritmos como Máquina de Vetor Suporte e Correlação de Imagem Digital também se mostram promissoras. A variedade de métodos reforça a necessidade de melhoria contínua das aplicações que envolvem inteligência artificial de modo a obter a solução mais precisa com menor custo computacional.

Palavras-Chave: Monitoramento de integridade estrutural; Processamento digital de imagens; Inspeção visual; Obras civis; Monumentos históricos

5.2 Introdução ao monitoramento de integridade estrutural

Ao longo do tempo de vida das edificações, a estrutura é submetida à ação dos esforços solicitantes e intempéries, fatores que causam a deterioração e consequente surgimento de patologias. Para a construção civil, as patologias referem-se a todas as manifestações cuja ocorrência no ciclo de vida da edificação venham prejudicar o desempenho esperado da obra (Andrade; Silva, 2005). Por esse motivo, é importante a execução de inspeções e manutenções periódicas a fim de identificar danos potenciais e implementar ações corretivas a fim de garantir o bom desempenho da edificação, ou seja, a tentativa de manter as características originais do projeto e não causar danos ou desconforto aos usuários da edificação.

A forma mais comum de decisão para a manutenção de estruturas, em geral, é estabelecer um critério de temporal. Entretanto, os custos de manutenção podem aumentar significativamente quando considerado apenas esse parâmetro, visto que os fatores que geram a deterioração em obras não são constantes. Como alguns problemas não são perceptíveis no cotidiano, aplicar ciclos inadequados de inspeção implica que as patologias dificilmente serão identificadas nos estágios iniciais para corrigi-las, algo que pode ser mitigado com a aplicação de sistemas de monitoramento de integridade estrutural. Ao implementar medidas de monitoramento regulares ou contínuas, visa-se evitar falhas estruturais inesperadas (Katam; Pasupuleti; Kalapatapu, 2023) e adotar medidas eficazes e otimizadas de correção.

Ocasionalmente, nos deparamos com notícias sobre interdição de obras devido a risco estrutural, especialmente viadutos. Em casos mais extremos, eles figuram os relatos de acidentes que poderiam ser evitados caso houvesse a aplicação do monitoramento de integridade estrutural. Um exemplo foi o trecho do Viaduto da Marginal Pinheiros em São Paulo/SP, que cedeu em novembro de 2018, o qual possuía pilares de sustentação fissurados, armação de ferragem sob o concreto exposta e corroída, infiltração e drenagem ineficientes. Casos como esse destacam a importância do monitoramento da integridade estrutural como forma de garantir a segurança dos usuários e evitar grandes prejuízos materiais e à sociedade, obtendo dados sobre a situação atual de uma estrutura e conhecendo as necessidades reais de manutenção.

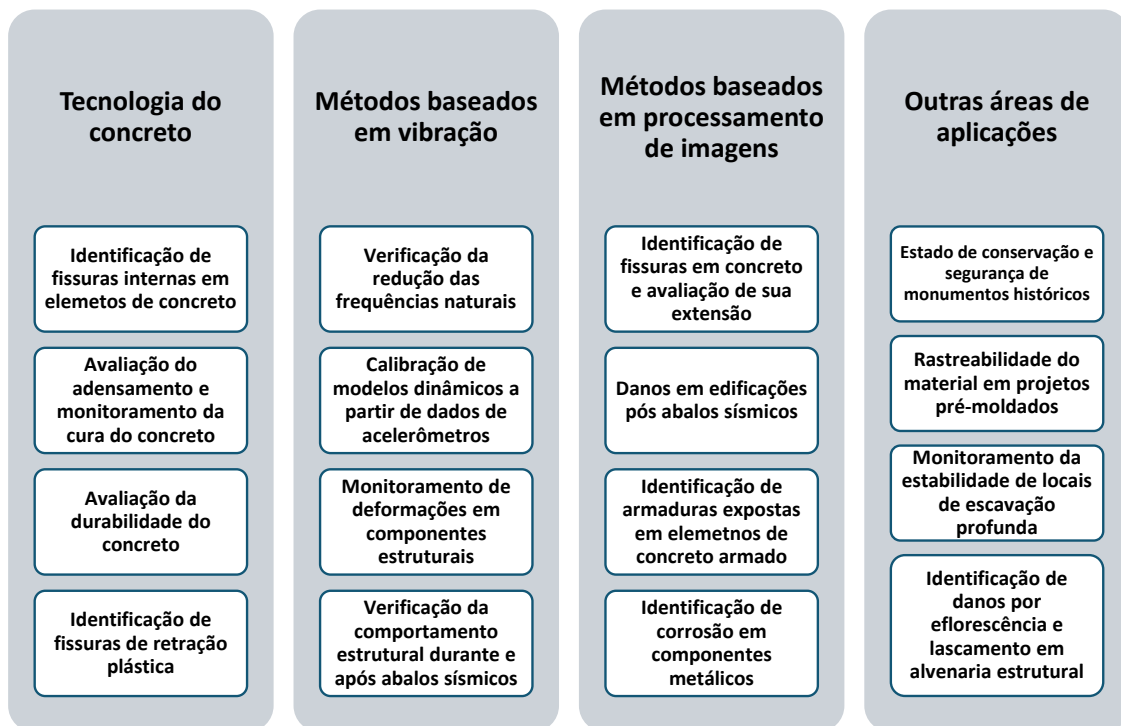
Abordar o monitoramento de integridade estrutural permite o acompanhamento contínuo da integridade de sistemas e estruturas durante toda a sua vida útil operacional, o que reduz a dependência de inspeções periódicas e diminui os custos de manutenção (Katam; Pasupuleti; Kalapatapu, 2023) uma vez que substitui a manutenção programada pela necessária. É importante ressaltar que esse método permite avaliar a condição da degradação estrutural antes que danos reais sejam causados à própria estrutura.

Conforme Rimkus, Podvieszko e Gribniak (2015), em estruturas de concreto, “a fissuração é um dos primeiros indícios da degradação das estruturas de concreto. Para garantir a segurança e o desempenho durante a vida útil, a detecção de fissuras é a parte mais importante da manutenção estrutural”, o que exemplifica a importância da boa abordagem da técnica de monitoramento de integridade estrutural.

Diferentes métodos são aplicáveis à inspeção e monitoramento de integridade estrutural, separadas de acordo com o tipo e fonte de dados que serão avaliados, podendo ser visual, vibracional, emissão acústica, executadas por ultrassom, partículas magnéticas, radiográfica ou corrente elétrica, com alguns exemplos citados na Figura 1. Independentemente do método, os sistemas avançados para inspeção estrutural de quaisquer naturezas são realizados por meio de quatro etapas (Rytter, 1993):

- I. **Detecção da existência do dano:** indicativo qualitativo de que pode haver dano estrutural;
- II. **Localização:** obter informações sobre o local em que o dano ocorre;
- III. **Classificação e avaliação da extensão do problema:** qualificar o tipo de dano e dimensões;
- IV. **Consequências:** caracterizar o nível atual de segurança estrutural para o grau do dano identificado.

Figura 1 – Principais aplicações do monitoramento de integridade estrutural



Fonte: Autores.

Como a forma mais comum e antiga, a inspeção visual faz uso de ferramentas complementares, como martelo, câmera fotográfica e croquis no processo. Recentemente, o uso de Veículos Aéreos Não Tripulados (VANTs) e drones (Figura 2) apresenta rápido crescimento em muitos domínios de aplicação civil, incluindo monitoramento em tempo real, fornecendo cobertura sem fio na inspeção de infraestrutura civil (Shakhatreh et al., 2019) e, conseqüentemente, maior agilidade e precisão a coleta de informações em algumas avaliações. Apesar de a acurácia estar associada à experiência do profissional e subjetividade para a interpretação do fato observado e relatórios anteriores, a inspeção visual proporciona uma importante visão geral e indica se uma outra técnica será necessária (Rytter, 1993). Seria possível, então, tornar o procedimento de inspeção visual mais ágil e menos subjetivo? A resposta está na aplicação de recursos de visão computacional e inteligência artificial para o tratamento dos dados coletados.

Figura 2 - Representação de uma inspeção visual com utilização de drone



Fonte: Imagem gerada por inteligência artificial ChatGPT 4.0 da OpenAI.

5.3 *Machine learning* para inspeção visual em engenharia estrutural diagnóstica

Os domínios da aplicação do *machine learning* em engenharia estrutural concentram-se em cinco áreas principais: 1) membros estruturais, 2) material, 3) integridade estrutural e detecção de danos, 4) análise de projeto e 5) situação de incêndio. Entre elas, indica-se que a detecção de danos e monitoramento de integridade estrutural é o terceiro assunto com mais estudos de aplicação (estimado em 18% dos estudos), sendo que a avaliação de material e avaliação de membros estruturais representam, respectivamente, 29% e 38% das publicações (Thai, 2022).

No segmento do monitoramento de integridade estrutural por inteligência artificial e visão computacional, algoritmos do tipo Redes Neurais Convolucionais (RNC)

são aplicados com sucesso devido à capacidade em extrair *features* automaticamente a partir dos dados (imagens) de entrada, eliminando a necessidade de conhecimento humano prévio em suas determinações. A exemplo da detecção de fissuras em estruturas de concreto, as RNCs possuem melhor qualidade para a classificação de imagem ou segmentação a nível de pixel em comparação a outras arquiteturas (Atha; Jahanshahi, 2018; Yu; Wang; Gu, 2019; Sony et al., 2021; Thai, 2022).

O que torna as RNCs superiores às Redes Neurais comuns para a avaliação de imagens é o funcionamento em três camadas, porém camadas adicionais, como a *dropout*, são aplicáveis para prevenir o *overfitting* (Sony et al., 2021). Entretanto, nem todas as RNCs executam com eficácia as tarefas relacionadas ao tratamento de casos do mundo real no domínio da visão computacional devido a um grande problema relacionado à insuficiência de dados de imagem (Cha; Choi; Büyüköztürk, 2017). Esse problema pode ser corrigido com ferramentas para transformar um *dataset* pequeno a um *dataset* de treinamento apto para o aprendizado de máquina, que consiste em modificar o nível de ruído, contraste, desfoque e rotação das imagens destinadas ao *dataset* de treinamento (Sony et al., 2021).

É importante ressaltar que as RNCs não são os únicos algoritmos que figuram entre as análises de imagens para o monitoramento de integridade estrutural. Técnicas menos complexas, como a Correlação de Imagem Digital e Máquinas de Vetor Suporte são aplicadas com sucesso. Além disso, nem sempre o algoritmo baseado em inteligência artificial puro é suficiente, necessitando que as imagens passam por um pré-processamento para trabalhar os dados em nível de pixel e possibilitar a análise principal.

5.4 Aplicações da inspeção visual por inteligência artificial para a integridade estrutural de obras

Embora os algoritmos de inteligência artificial, descritos na literatura de engenharia diagnóstica, estejam majoritariamente focados em estruturas de concreto (Thai, 2022), a eficiência observada da aplicação para identificação de fissuras neste sistema estrutural indica potencial de uso para detecção de outras patologias (Santos et al., 2022). Na área de estruturas metálicas, as aplicações podem variar desde o nível do material, como o processo de fabricação dos elementos em aço ainda no setor siderúrgico (Cui et al., 2022), até ao controle da resistência do material, e exploração de métodos para identificação de patologias superficiais como corrosão, fissuras, formação de poros etc. (Patil et al., 2022). Para introduzir as possibilidades de usos da inteligência artificial em engenharia de monitoramento de integridade estrutural, a seguir são apresentados exemplos de aplicações de RNCs e técnicas de visão computacional para identificação de patologias em estruturas de concreto e metálicas.

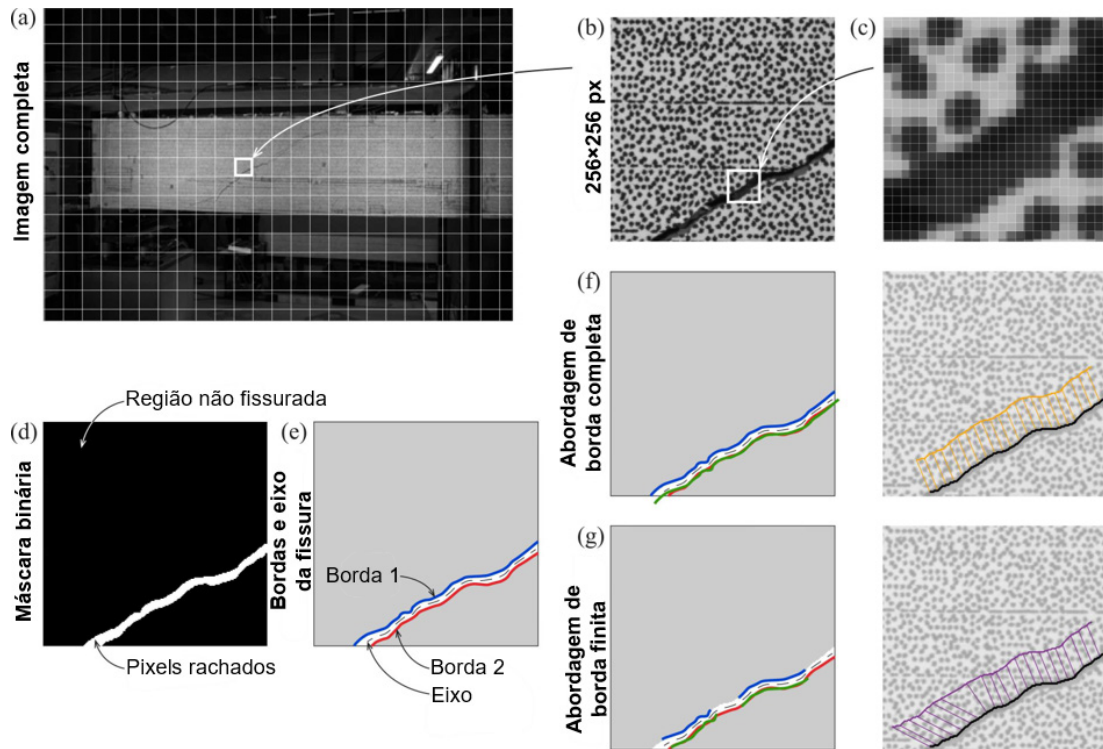
5.4.1 Fissuras em concreto armado

Existem variadas técnicas que se mostram promissoras para a avaliação de estruturas em concreto armado, como o uso da Correlação de Imagem Digital (CID) para o processamento de fotografias. Essa exige que a superfície seja tratada com um padrão aleatório de pontos que possuam alto contraste. O processamento baseia-se na análise da matriz de valores numéricos associados aos canais de intensidade de uma imagem, geralmente representados em uma escala de tons de cinza, onde os valores são processados por algoritmos de correlação para identificar e rastrear pontos correspondentes (denominados pares conjugados) entre duas imagens capturadas antes e após a deformação (Wong; Ho, 1986).

A CID pode ser aplicada para analisar o comportamento de fissuração, por exemplo, na zona de flexão pura de uma viga de concreto armado, identificando-as e avaliando a propagação na superfície. A análise inicial das imagens por esse método objetiva localizar os denominados “pixels rachados”, ou seja, obter as coordenadas dos pixels que correspondem à localização das fissuras na superfície, o que possibilita também determinar a distância entre elas. Entretanto, “a determinação das distâncias das fissuras pode ser extremamente complicada ou mesmo dificilmente possível devido à existência de fissuras inclinadas e/ou múltiplas” (Rimkus; Podviezko; Gribniak, 2015). Além disso, a técnica CID requer imagens de vários momentos para a localização da trinca, o que pode ser significativamente limitada para uma aplicação real, que exige o monitoramento a longo prazo devido aos princípios do algoritmo de correlação.

Outra limitação da CID consiste na impossibilidade de determinar de forma exata a geometria da fissura e a sua cinemática. Neste contexto, Vincens, Corres e Muttoni (2024) desenvolveram uma técnica em duas etapas para complementar a análise CID. A primeira etapa é a segmentação das fissuras nas imagens para gerar a categorização como pixels rachados ou não rachados a partir da subdivisão em janelas de 256x256 px. Para essa finalidade, as redes de aprendizagem profunda implementadas por Rezaie et al. (2020) de arquitetura TernausNet podem ser usadas, em que as máscaras binárias CID são recombinadas na imagem original em tamanho real. A segunda etapa é a estimativa da cinemática inicial da rachadura com base nas imagens binárias usando o algoritmo proposto por Pantoja-Rosero et al. (2022). Esse algoritmo delimita o eixo e as bordas da fissura e estima a transformação de deslocamento de corpo rígido mais adequada, permitindo determinar a cinemática da rachadura. Quando a abertura da fissura é suficientemente pequena, o deslocamento de corpo rígido é uma suposição válida e o segmento completo da fissura pode ser reconstruído. Caso contrário, o algoritmo compara segmentos parciais, fornecendo apenas trechos do contorno. Esse processo de análise e resultados é exemplificado nas sequências da Figura 3.

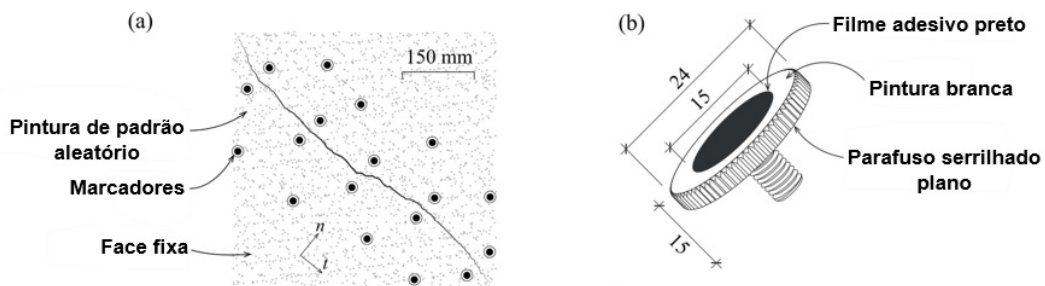
Figura 3 – Processo de caracterização de fissuras em concreto, onde (a) imagem original em tamanho real, (b) segmentação 256x256 pixels, (c) região ampliada da fissura, (d) máscara binária resultante, (e) eixo e bordas da fissura e exemplos da cinemática usando (f) a abordagem de borda completa e (g) a abordagem de borda finita



Fonte: Traduzido de Vincens, Corres e Muttoni (2024), sob a licença Creative Commons.

A instalação do sistema de medição é a principal desvantagem em comparação com medições tradicionais simples. No entanto, seu uso é bem justificado em casos em que alta precisão é necessária para caracterizar múltiplas fissuras ou grandes superfícies. Os resultados obtidos são promissores para obter informações de alta qualidade sobre a geometria e os deslocamentos da fissura, porém fornece apenas a informação instantânea da condição estrutural. Para monitorar a atividade da fissura, Marcadores posicionados na região próxima delas servem como elementos referenciais que aumentam a eficácia da análise da propagação da abertura, em um arranjo exemplificado na Figura 4.

Figura 4 – Exemplo do arranjo de monitoramento da atividade da fissura para (a) preparo da superfície e fixação dos marcadores e (b) detalhamento do marcador



Fonte: Traduzido de Vincens, Corres e Muttoni (2024), sob a licença Creative Commons.

Em casos em que não se deseja realizar algum tratamento da superfície, como no uso da CID, as RNCs são boas ferramentas que podem tanto detectar, como também quantificar, em nível de detalhe, a abertura de fissuras. Para isso, as RNCs, como AlexNet, GoogLeNet, Resnet-18 e VGG-16, devem ser associadas a técnicas de processamento de imagens em três etapas, conforme descrito por Miao e Srimahachota (2019):

- I. Pré-processamento, incluindo a correção da perspectiva das imagens coletadas em campo e, apenas em casos controlados, a captura em diferentes perspectivas e rotações. Posteriormente, as fotografias devem ser recortadas de acordo com uma malha de pixels;
- II. Detecção de fissuras, que consiste no processamento das imagens pelo algoritmo treinado especificamente para o caso ou por técnicas de transferência de aprendizagem;
- III. Pós-processamento, onde os dados de saída são convertidos em imagens em escala de cinza e aplicado filtro para aumentar o contraste e máscaras para redução de ruído e suavização. Após, as bordas das fissuras estão aptas para delimitação e análise das propriedades, tais como largura de abertura, comprimento e orientação.

Esse processo, comparando-se com a classificação de imagem tradicional, que visa apenas detectar o problema, é econômico e abrange também a quantificação para um melhor panorama sobre a condição estrutural, minimizando a necessidade de avaliação manual complementar. Porém algumas fissuras podem não ser detectadas devido, principalmente, ao fato de serem finas ou a iluminação irregular. Essa faixa de falha pode ser evitada com a utilização de imagens de maior resolução ou aprimorando a aplicação.

Não somente condições de iluminação, como também fatores ambientais no momento da captura das imagens, especialmente com o uso de equipamentos aéreos, podem resultar em ruídos que interferem na qualidade do processamento. Logo, a etapa de pré-processamento da aplicação de uma técnica baseada em inteligência artificial pode exigir o uso de filtros para remoção de ruído, como o de média, mediana e gaussiano (Santos et al., 2023). Esses filtros tornam a aparência da imagem mais difusa de diferentes formas, possuindo como referência o tamanho do *kernel* da operação. O filtro de média realiza uma suavização linear, calculando a média dos valores dos pixels em relação ao central; o filtro de mediana realiza uma suavização não linear, obtendo como referência a mediana dos valores dos pixels abrangidos pelo *kernel*; o filtro Gaussiano, por sua vez, realiza uma média ponderada, cujos pesos seguem aproximadamente uma distribuição gaussiana (Gonzalez; Woods, 2010).

Para que essa correção seja aplicada no processo, o monitoramento necessita previamente da preparação de um banco de dados com imagens aéreas de drones padronizadas em tamanho e resolução e da aplicação dos filtros de imagem a serem


analisados. A análise das fissuras em si necessita um algoritmo multiestágio, com uma primeira etapa para reduzir ruído e detectar bordas, como o detector de Canny que é especializado nessa tarefa, e uma segunda etapa para identificar o que é fissura e classificá-la, algo obtido facilmente com o uso de Máquina de Vetor Suporte. Entre os três tipos de filtros, o de mediana demonstra melhor desempenho como método de pré-processamento das imagens, apresentando superioridade em precisão, *recall* e acurácia geral na detecção de danos semelhantes a fissuras em estruturas de concreto (Santos et al., 2023).

5.4.2 Detecção de armadura exposta em elementos de concreto armado

A corrosão das armaduras é a principal causa de danos e falhas precoces em estruturas de concreto armado (Verma; Bhadauria; Akhtar, 2014) e, conseqüentemente, necessita ser detectada por meio do monitoramento estrutural contínuo e tratada no estágio inicial para garantir sua integridade. Geralmente o monitoramento é feito por meio de ensaios não destrutivos, os quais se baseiam em sensores eletromagnéticos (Santos et al., 2022), a exemplo do *Ground Penetrating Radar* (GPR) (Ghodoosi et al., 2018; Ahmed; Manh La; Tran, 2022), entre outros. Já em estágios mais avançados, é possível detectar e avaliar a evolução das patologias através de inspeção visual, incluindo o uso de registros fotográficos obtidos por VANTs e drones (Santos et al., 2022) a depender do grau de dificuldade imposta pelo porte da estrutura como em sistemas de armazenamento de grãos do tipo silo em concreto armado.

Para essa aplicação, como a estrutura ocupa uma grande área, o drone necessita de um equipamento GPS além da câmera fotográfica para georreferenciar o registro do dano. Após, as imagens são combinadas para formar um mosaico ortofotográfico georreferenciado da superfície estrutural (Santos et al., 2022). Por vezes, a precisão do GPS acoplado necessita ser aprimorada com a técnica de Posicionamento Cinemático em Tempo Real (*Real Time Kinematic – RTK*) no momento da coleta de dados, a qual faz uso de uma estação receptora de dados de posicionamento via satélite. A Figura 5 exemplifica o método para coletar dados fotográficos georreferenciados para posterior processamento via RNC.

Figura 5 – Procedimento para captura e análise de imagens georreferenciadas com uso de drones para detecção de dano estrutural em grandes construções



Fonte: Traduzido de Santos et al. (2022), sob a licença Creative Commons.

Na aplicação realizada por Santos et al. (2022), a rede neural AlexNet foi treinada com imagens capturadas em diferentes ângulos, distâncias de voo e horários do dia, cortadas no padrão 227227 px, resultando em 20.000 imagens de superfícies de concreto intactas e 20.000 imagens de superfícies com vergalhões expostos. O treinamento AlexNet foi realizado utilizando o *Deep Learning Toolbox* do Matlab®, reduzindo as 1.000 categorias originais do algoritmo para apenas as duas de interesse. O silo foi dividido em duas regiões de captura para validação e, como resultados, foram encontrados 4 falsos positivos na região A, resultando em uma precisão de 98,33%, e apenas 1 falso positivo na região B, resultando em uma precisão de 99,60%, ambas superiores à validação.

5.4.3 Amassamentos em elementos estruturais de Steel Frame

Identificar imperfeições de elementos estruturais metálicos que possam interferir na vida útil da edificação oferece maiores desafios à análise baseada em sistemas de visão computacional e aprendizado profundo. Quando o problema não é referente a imperfeições locais como amassamentos e sim imperfeições globais como torções ou flexões, o processo requer uma quantidade elevada de dados para obter bons níveis de precisão (Kim et al., 2021). Nesses cenários, as Redes Neurais Convolucionais Profundas (*Deep Convolutional Neural-Networks*) como das arquiteturas DenseNet, MobileNet e ResNet, as quais possuem maior número de camadas em relação às RNCs convencionais, apresentam acurácia aceitável.

Como exemplo de aplicação, Kim et al. (2021) realizou a captura de imagens de perfis quadrados para *steel frame* nas dimensões 50x50 mm e 75x75 mm, nas condições com deformação de amassamentos e peças intactas. A captura das imagens foi realizada em variando a combinação de distâncias, alturas e ângulos de captura da câmera ao objeto alvo, com posterior recorte das imagens para um tamanho padrão 224x224 px. Os autores empregaram uma etapa final utilizando o algoritmo Softmax e a técnica de visualização Grad-CAM (*Gradient-weighted Class Activation Mapping*). Essa técnica gera um “mapa de calor” sobre a imagem de entrada a partir das ativações da última camada convolucional, indicando as regiões mais relevantes para a classificação. Durante o processamento da rede neural, a matriz de dados inicial é filtrada para armazenar apenas as informações de interesse, resultando em uma matriz reduzida. O Grad-CAM, então, reescala essa matriz reduzida para torná-la compatível em dimensão com a imagem original, permitindo sobrepor o mapa de calor à entrada. Dessa forma, obtém-se uma visualização intuitiva que delimita a região danificada e fornece uma noção da intensidade do dano, facilitando a identificação em laudos ou confirmações presenciais.

5.4.4 Corrosão em estruturas metálicas

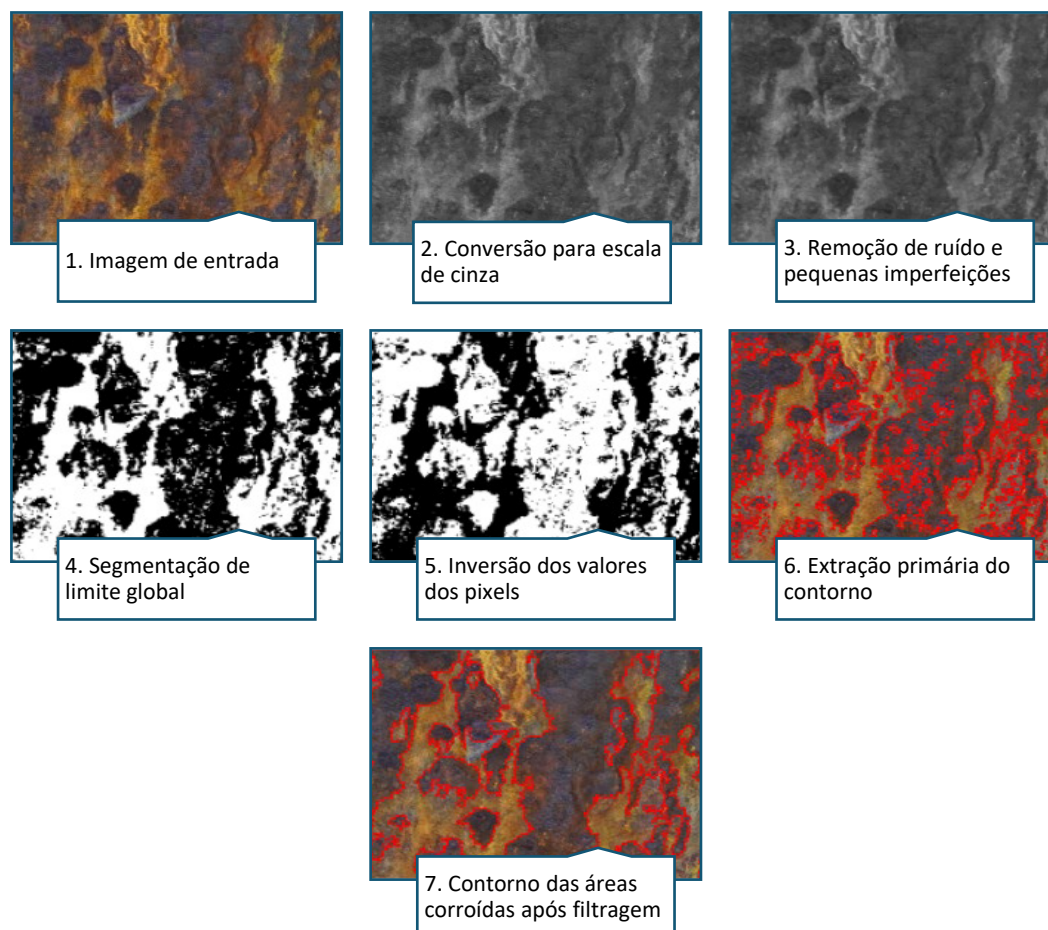
Superfícies metálicas estão sujeitas ao processo natural e gradual de deterioração e perda de propriedades estruturais como resultado de reações químicas ou eletroquímicas com fatores ambientais, principalmente umidade, oxigênio, sais e ácidos, denominado como corrosão (North; MacLeod, 1987), cuja principal preocupação é a redução da área de material. Esse dano pode progredir sem ser detectado até atingir um nível de falha repentina e, portanto, é necessário que as áreas sujeitas à corrosão sejam monitoradas para detectar o problema precocemente (Liu; Li, 2023), possibilitando que a extensão do dano seja avaliada para a aplicação das medidas corretivas. Entretanto, na prática, a forma, a localização, o tamanho, o grau e a quantidade de danos à camada corroída dos componentes de aço são aleatórios (Procópio, 2019), fatores que dificultam a inspeção visual.

Para detectar a formação de corrosão em estruturas metálicas, Atha e Jahanshahi (2018) verificaram a performance de duas arquiteturas de algoritmos disponíveis para uso, sendo elas a VGG16 e ZFNet, e duas arquiteturas propostas. Os autores procederam o estudo com a captura de imagens de superfícies metálicas corroídas e recortaram nos padrões 128128 px, 6464 px e 3232 px, sem realizar outras edições gráficas, para avaliar também a malha ótima de pixels para os dados do *dataset*. Conforme demonstrado e discutido, o refinamento excessivo da malha (menor número de pixels) reduziu a capacidade de aprendizado das redes neurais e aumentou probabilidade de incoerência na detecção do problema. Um ponto importante foi o desenvolvimento de uma rede neural mais rápida comparada às consolidadas no mercado e com bons resultados para a aplicação em identificação de corrosão. Em se tratando de metodologias de monitoramento, que demandam capacidade de processamento do equipamento, não basta apenas que os algoritmos possuam ótima precisão de classificação, necessitam também de custos computacionais adequados.

Um importante indicador para quantificar o problema é determinar a porcentagem da área superficial do elemento metálico que está corroída, o que pode ser obtido pelo processo de Han et al. (2024) aplicável após a identificação da existência de corrosão com RNCs, como GoogleNet, ResNet101 e DenseNet. As etapas, exemplificadas na Figura 6, envolvem, primeiramente, a conversão da escala RGB à escala de cinza, onde os pixels de áreas corroídas possuirão valores mais próximos a 0 (preto), enquanto os pixels não corroídos possuirão valores mais próximos a 255 (branco). A finalização do tratamento inicial da imagem inclui a corrosão topológica, com a remoção de ruídos, pequenas fissuras e objetos de fundo da imagem. A etapa seguinte envolve a segmentação global, onde um valor em escala de cinza é utilizado como ponto divisor para obter apenas pixels 0 ou 255, o qual deve ser estimado com

base em uma imagem do *dataset* onde há certeza da proporção de área corroída. A inversão dos valores resultantes dos pixels serve para facilitar a extração do contorno, fazendo com que os pixels de corrosão sejam brancos. Finalmente, áreas muito pequenas são unificadas para obter áreas maiores na delimitação da corrosão.

Figura 6 – Procedimento para quantificar a área corroída em superfícies metálicas



Fonte: Imagens de Han et al. (2024) reproduzidas sob a licença Creative Commons.

5.4.5 Monitoramento em tempo real baseado em visão computacional


Os exemplos anteriores, mesmo com a aplicação de drones ou VANTs, realizam o processamento digital de imagens em servidores em solo, o que requer consumo de tempo para a transmissão dos dados coletados ou a transferência contínua, o que requer uma alta largura de banda. Em alternativa, os sistemas de detecção de danos em tempo real acoplam o processamento em drones para que os dados transmitidos sejam apenas referentes às inconformidades, reduzindo a largura de banda necessária e minimizando problemas associados à perda de dados caso a conexão seja interrompida (Kumar et al., 2021).

Neste cenário, Kumar et al. (2021) apresentaram um sistema de detecção de danos em tempo real baseado em múltiplos drones para identificar tanto fissuras (*cracks*), como também armaduras expostas em estruturas de concreto (*spall*). As imagens são processadas em algoritmo de localização e identificação de objetos em imagens *You Only Look Once* versão 3 (YOLO-v3) treinado para o caso, o qual automaticamente subdivide a imagem capturada em 32, 16 e 8 vezes e realiza o cruzamento dos dados das três análises para compor os dados de saída. O *hardware* do sistema proposto inclui um drone com controlador de voo Pixhawk, câmera Logitech, e GPU Nvidia Jetson-TX2 com Wi-Fi integrado, permitindo captura de imagens, processamento contínuo e comunicação eficiente. O modelo YOLO-v3 detectou fissuras aproximadamente maiores que 0,2 mm a uma distância de 40 centímetros e armadura exposta de forma confiável, demonstrando-se eficaz para inspeções assistidas em tempo real de estruturas em concreto.

Para o segmento de elementos metálicos, a arquitetura YOLO-v8 demonstra-se como a mais confiável para aplicações reais, especialmente em cenários complexos, que envolvem superfícies corroídas em termos de velocidade, segmentação e visualização (Casas et al., 2024). Nesse sentido, Yılmaz, Nayır e Erdoğan (2025) realizaram testes de detecção em tempo real de corrosão utilizando algoritmos U-net, Detecton2 e YOLO-v8. Entre esses métodos, o YOLO-v8 identifica a corrosão em único estágio e possui versões com menor custo de processamento, entretanto igualmente eficientes, apresentando também melhor desempenho para a delimitação da caixa de contorno do objeto identificado.

Como o uso de algoritmos YOLO proporciona o acompanhamento remoto, o operador em solo pode acompanhar os resultados com a visualização em *softwares*. A exemplo da Figura 7, o resultado gera uma caixa de contorno no objeto detectado e a informação da sua classe e, inclusive, variação de cores para melhor distinção. Esse monitoramento possui ainda a vantagem de verificar a existência de falhas na detecção para posterior aprimoramento, como na Figura 7 em que algumas fissuras mais finas parecem ofuscadas por problemas mais evidentes.

Figura 7 – Exemplo de visualização em software da identificação de patologias estruturais em concreto armado com sistema YOLO-v3 em software



Fonte: Kumar et al. (2021), reproduzido sob a licença Creative Commons.

5.5 Considerações Finais

Conforme abordado ao longo do capítulo, não apenas as manutenções periódicas são importantes para manter a segurança, qualidade e bom desempenho em serviço das estruturas em geral, como também a realização de inspeções para conhecer o real estado. Assim, é possível executar interferências mais precisas, satisfazendo as necessidades de uso que acompanham a demanda. Importante lembrar que boas atividades de manutenção e readequação garantem menores prejuízos materiais e sociais.

Os estudos apresentados neste capítulo são exemplos de possibilidades e eficiência da aplicação de inteligência artificial para o monitoramento de integridade estrutural a partir de imagens, reduzindo o uso de sensores e custos de implantação do sistema em empresas. Eles também demonstram oportunidades de aplicações conjuntas, tanto agregando outros códigos para melhorar os dados de saída, como

também possibilitar que uma rede neural seja treinada para identificar mais de uma patologia estrutural, proporcionando o avanço para o desenvolvimento de uma aplicação comercial dos algoritmos para a engenharia diagnóstica de estruturas.

Sistemas que utilizam recursos da inteligência artificial em engenharia estrutural facilitam os procedimentos de inspeção e monitoramento, tornando um processo repetitivo e longo em uma tarefa interativa e ágil, reduzindo o tempo necessário para a realização sem comprometer a qualidade dos resultados. Conforme apresentado, pode-se obter dados sobre a integridade estrutural que sejam qualitativos e/ou quantitativos, de acordo com a abordagem, visto que os métodos apresentados são capazes de realizar apenas a detecção e classificação, levando a avaliação da extensão dos danos e estimativa do tempo de vida útil a serem executados por outros métodos. Em se tratando da aplicação de inteligência artificial para o campo de estudo deste capítulo, não existe um algoritmo perfeito, mas sim a técnica mais adequada e adaptada para suprir as necessidades da análise. Isso provém de um processo contínuo de pesquisa e desenvolvimento para equilibrar a eficácia e eficiência, resultando em códigos cada vez mais precisos e com menor custo computacional.

5.6 Agradecimentos

À Universidade Federal de Ouro Preto (UFOP), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Fundação Gorceix pelo apoio financeiro e incentivo à pesquisa.

5.7 Referências

AHMED, A.; MANH LA, H.; TRAN, K. Rebar detection and localization for bridge deck inspection and evaluation using deep residual networks. **Automation in Construction**, [S.l.], v. 120, p. 103.393, 2020. DOI: <https://doi.org/10.1016/j.autcon.2020.103393>.

ANDRADE, T.; SILVA, A. J. C. Patologia das Estruturas. In: ISAIA, G. C. (Org.). **Concreto: ensino, pesquisa e realizações**. São Paulo: IBRACON, 2005.

ATHA, D. J.; JAHANSHAH, M. R. Evaluation of deep learning approaches based on convolutional neural networks for corrosion detection. **Structural Health Monitoring**, [S.l.], v. 17, p. 1.110–1.128, 2018. DOI: <https://doi.org/10.1177/1475921717737051>.

CASAS, E. et al. A comparative study of YOLOv5 and YOLOv8 for corrosion segmentation tasks in metal surfaces. **Array**, [S.l.], v. 22, p. 100.351, 2024. DOI: <https://doi.org/10.1016/j.array.2024.100351>.

CHA, Y.-J.; CHOI, W.; BÜYÜKÖZTÜRK, O. Deep learning-based crack damage detection using convolutional neural networks. **Computer-Aided Civil and Infrastructure Engineering**, [S.l.], v. 32, n. 5, p. 361-378, 2017. DOI: <https://doi.org/10.1111/mice.12263>.

CUI, C. et al. Physical metallurgy guided deep learning for yield strength of hot-rolled steel based on the small, labeled dataset. **Materials & Design**, [S.l.], v. 223, 2022. DOI: <https://doi.org/10.1016/j.matdes.2022.111269>.

GONZALES, R. C.; WOODS, R. E. **Processamento digital de imagens**. 3. ed. São Paulo: Pearson Prentice Hall, 2010. 624 p.

GHODOOSI, F. et al. Method for developing and updating deterioration models for concrete bridge decks using GPR data. **Automation in Construction**, [S.l.], v. 91, p. 133-141, 2018. DOI: <https://doi.org/10.1016/j.autcon.2018.03.014>.

HAN, S. et al. Intelligent analysis of corrosion characteristics of steel pipe piles of offshore construction wharfs based on computer vision. **Heliyon**, [S.l.], v. 10, n. 2, e24142, 2024. DOI: <https://doi.org/10.1016/j.heliyon.2024.e24142>.

KATAM, R.; PASUPULETI, V. D. K.; KALAPATAPU, P. A review on structural health monitoring: past to present. **Innovative Infrastructure Solutions**, [S.l.], v. 8, n. 248, 2023. DOI: <https://doi.org/10.1007/s41062-023-01217-3>.

KIM, B. et al. Investigation of steel frame damage based on computer vision and deep learning. **Automation in Construction**, [S.l.], v. 132, 2021. DOI: <https://doi.org/10.1016/j.autcon.2021.103941>.

KUMAR, P. et al. Real-time concrete damage detection using deep learning for high rise structures. **IEEE Access**, [S.l.], v. 9, p. 112.312–112.331, 2021. DOI: <https://doi.org/10.1109/ACCESS.2021.3102647>.

LIU, M.; LI, W. Prediction and analysis of corrosion rate of 3C steel using interpretable machine learning methods. **Materials Today Communications**, [S.l.], v. 35, 2023. DOI: <https://doi.org/10.1016/j.mtcomm.2023.106408>.

MIAO, P.; SRIMAHACHOTA, T. Cost-effective system for detection and quantification of concrete surface cracks by combination of convolutional neural network and image processing techniques. **Construction and Building Materials**, [S.l.], v. 293, 2021. DOI: <https://doi.org/10.1016/j.conbuildmat.2021.123549>.

NORTH, N. A.; MACLEOD, I. D. Corrosion of metals. In: PEARSON, C. **Conservation of Marine Archaeological Objects**. [S.l.]: Butterworth-Heinemann, p. 68-98, 1987. DOI: <https://doi.org/10.1016/B978-0-408-10668-9.50010-1>.

PANTOJA-ROSETO, B. G. et al. Determining crack kinematics from imaged crack patterns. **Construction and Building Materials**, [S.l.], v. 343, p. 128.054, 2022. DOI: <https://doi.org/10.1016/j.conbuildmat.2022.128054>.

PATIL, S. et al. Deep learning-based methods for detecting surface defects in steel plates. In: SEHGAL, R. et al. **Smart Electrical and Mechanical Systems**. [S.l.]: Academic Press, p. 87-107, 2022. DOI: <https://doi.org/10.1016/B978-0-323-90789-7.00001-4>.

PROCÓPIO, L. The role of biofilms in the corrosion of steel in marine environments. **World Journal of Microbiology and Biotechnology**, [S.l.], v. 35, n. 5, p. 73, 2019. DOI: <https://doi.org/10.1007/s11274-019-2647-4>.

REZAI, A. et al. Comparison of crack segmentation using digital image correlation measurements and deep learning. **Construction and Building Materials**, [S.l.], v. 261, p. 120-474, 2020. DOI: <https://doi.org/10.1016/j.conbuildmat.2020.120474>.

RIMKUS, A.; PODVIEZKO, A.; GRIBNIAK, V. Processing digital images for crack localization in reinforced concrete members. **Procedia Engineering**, [S.l.], v. 122, p. 239-243, 2015. DOI: <https://doi.org/10.1016/j.proeng.2015.10.031>.

RYTTER, A. Vibrational based inspection of civil engineering structures. 1993. Tese (Doutorado) — Department of Building Technology and Structural Engineering, Aalborg Universitet. Dinamarca, 1993.

SANTOS, B. S. et al. On the use of different image filters for damage detection in concrete-like structures using aerial photographs from UAV. In: CONGRESSO INTERNACIONAL DE ENGENHARIA MECÂNICA, 27. Florianópolis: ABCM, 2023. DOI: <https://doi.org/10.26678/ABCM.COBEM2023.COB2023-1825>.

SANTOS, R. et al. Detection of exposed steel rebars based on deep-learning techniques and unmanned aerial vehicles. **Automation in Construction**, [S.l.], v. 139, 2022. DOI: <https://doi.org/10.1016/j.autcon.2022.104324>.

SHAKHATREH, H. et al. Unmanned aerial vehicles (UAVs): a survey on civil applications and key research challenges. **IEEE Access**, [S.l.], v. 7, p. 48.572-48.634, 2019. DOI: <https://doi.org/10.1109/ACCESS.2019.2909530>.

SONY, S. et al. A systematic review of convolutional neural network-based structural condition assessment techniques. **Engineering Structures**, [S.l.], v. 226, 2021. DOI: <https://doi.org/10.1016/j.engstruct.2020.111347>.

THAI, H.-T. Machine learning for structural engineering: a state-of-the-art review. **Structures**, [S.l.], v. 38, p. 448-491, 2022. DOI: <https://doi.org/10.1016/j.istruc.2022.02.003>.

VERMA, S. K.; BHADAURIA, S. S.; AKHTAR, S. Monitoring corrosion of steel bars in reinforced concrete structures. **The Scientific World Journal**, [S.l.], art. 957904, 9 p., 2014. DOI: <https://doi.org/10.1155/2014/957904>.

VINCENS, B.; CORRES, E.; MUTTONI, A. Image-based techniques for initial and long-term characterization of crack kinematics in reinforced concrete structures. **Engineering Structures**, [S.l.], v. 317, p. 118.492, 2024. DOI: <https://doi.org/10.1016/j.engstruct.2024.118492>.

WONG, K. W.; HO, W.-H. Close-range mapping with a solid-state camera. **Photogrammetric Engineering and Remote Sensing**, [S.l.], v. 52, n. 1, p. 67-74, 1986.

YILMAZ, Y.; NAYIR, S.; ERDOĞDU, Ş. Real-time detection of steel corrosion defects using semantic and instance segmentation models based on deep learning. **Materials Today Communications**, [S.l.], v. 44, 112.050, 2025. DOI: <https://doi.org/10.1016/j.mtcomm.2025.112050>.

YU, Y. et al. A novel deep learning-based method for damage identification of smart building structures. *Structural Health Monitoring*, [S.l.], v. 18, p. 143-163, 2019. DOI: <https://doi.org/10.1177/1475921718804132>.

5.8 Sobre os(as) autores(as)

Caroline Aparecida Ferreira é Engenheira Civil pela Universidade Federal de Lavras, mestre e doutoranda em Engenharia Civil na área de Estruturas e Construção pelo Programa de Pós-graduação em Engenharia Civil (PROPEC) da Universidade Federal de Ouro Preto (UFOP). Possui experiência em otimização estrutural aplicada a estruturas de madeira e mistas (concreto-madeira e aço-madeira) em situação de incêndio.

Cláudia Márcia Canazart é Engenheira Civil pela Faculdade de Ciências e Tecnologia de Viçosa e mestre em Engenharia Civil na área de Estruturas e Construção pelo Programa de Pós-graduação em Engenharia Civil (PROPEC) da Universidade Federal de Ouro Preto (UFOP).

Nalberth Vicentin Santana é Engenheiro Civil pela Universidade do Estado de Mato Grosso (UNEMAT), mestre e doutorando em Engenharia Civil na área de Estruturas e Construção pelo Programa de Pós-graduação em Engenharia Civil (PROPEC) da Universidade Federal de Ouro Preto (UFOP). Possui experiência em projetos de edificações em concreto armado, inspeção predial e otimização estrutural aplicada a elementos em aço fabricados em perfis formados a frio.

6 APRENDIZADO DE MÁQUINA PARA O MONITORAMENTO DA INTEGRIDADE DE PAREDES UTILIZANDO SMARTPHONES

Tales Humberto de Aquino Boratto¹, Heder Soares Bernardino²,
Alexandre Abrahão Cury³, Leonardo Goliatt da Fonseca⁴

¹ Pós-Graduação em Modelagem Computacional, Universidade Federal de Juiz de Fora.

² Departamento de Ciências da Computação, Universidade Federal de Juiz de Fora.

³ Pós-Graduação em Engenharia Civil, Universidade Federal de Juiz de Fora.

⁴ Departamento de Mecânica Computacional e Aplicada, Universidade Federal de Juiz de Fora.

6.1 Resumo

O monitoramento da integridade estrutural é fundamental para garantir a segurança e a longevidade de estruturas. Em particular, a análise do estado das paredes desempenha um papel crucial, pois essas estruturas influenciam tanto a estabilidade quanto a distribuição de cargas das construções. Adicionalmente, a utilização de *smartphones* para capturar o comportamento dinâmico de paredes surge como uma alternativa acessível e prática em comparação com sistemas tradicionais de monitoramento. Estudos anteriores demonstraram a viabilidade dessa abordagem para a identificação das anomalias, alcançando bons resultados. No entanto, o foco deste capítulo consiste em quantificar a severidade dos danos e usando apenas dados provenientes dos acelerômetros de tais dispositivos. Para isso, foram utilizados 12 atributos espectrais extraídos dos sinais e três modelos de aprendizado de máquina para a classificação das amostras quanto a três níveis de danos, além do estado íntegro da estrutura, a partir do conjunto de dados gerado por Sun (2023). Os resultados promissores alcançados, em torno de 99,21% em termos de acurácia, incentivam o aprofundamento desta abordagem em condições reais de monitoramento.

Palavras-Chave: Monitoramento de Integridade Estrutural; Sensoriamento por *Smartphone*; Análise de vibrações; Aprendizado de Máquina

6.2 Introdução

O monitoramento da integridade estrutural (*Structural Health Monitoring – SHM*) é um ramo da engenharia estrutural dedicado à identificação de danos em estruturas aeroespaciais, civis e mecânicas (Farrar; Worden, 2007). Essa área desempenha uma função significativa nos sistemas estruturais, especialmente em termos de confiabilidade, vida útil e garantia de segurança, uma vez que fatores como desgaste natural, eventos climáticos extremos, sobrecargas inesperadas e falhas de material podem comprometer a segurança das estruturas ao longo do tempo. Em particular, o monitoramento da integridade das paredes de construções modernas, como casas, edifícios e outros, também se tornou um aspecto relevante, pois elas desempenham um papel fundamental na distribuição de cargas e na manutenção da estabilidade estrutural. Portanto, em vez de esperar pela ocorrência visível de falhas, o SHM serve como uma ferramenta que permite a adoção de medidas preventivas e reparos direcionados antes que os danos se agravem ou até mesmo se tornem irreversíveis.

Tradicionalmente, os problemas de SHM envolvem quatro níveis de avaliação (Rytter, 1993): (I) determinar a existência de danos estruturais; (II) identificar sua localização; (III) quantificar sua gravidade; e, (IV) prognóstico. Além disso, há dois tipos principais de SHM: orientado por modelos (Sarmadi; Entezami; Ghalehnovi, 2020) e orientado por dados (Chen et al., 2021). O primeiro geralmente envolve o desenvolvimento de um modelo de elementos finitos (FE), enquanto o segundo emprega medições dinâmicas da estrutura. Nesse sentido, as abordagens orientadas por dados normalmente oferecem uma solução mais prática para identificar danos devido à menor complexidade de seu modelo computacional e à maior generalização (Alves; Cury, 2023). Entretanto, embora os métodos orientados por dados tenham se tornado cada vez mais importantes em aplicações de SHM, oferecendo ferramentas poderosas para detectar e diagnosticar danos em estruturas (Xu; Zhang; Liu, 2024; Kauss et al., 2024), sua eficácia depende muito da qualidade dos dados coletados. No SHM, os dados do sensor geralmente podem ser incompletos, ruidosos ou tendenciosos devido a fatores ambientais, envelhecimento do equipamento ou instalação inconsistente. Esses problemas podem levar a previsões não confiáveis, dificultando a detecção precisa de danos ou degradação sutis.

Diferentes estratégias e técnicas de aprendizado de máquina para o monitoramento estrutural surgiram recentemente, cada uma com suas vantagens e aplicações (Avci et al., 2021). Embora as abordagens supervisionadas e semi-supervisionadas sejam mais comumente usadas e tenham a vantagem de avaliar a qualidade da aprendizagem, elas exigem grandes conjuntos de dados rotulados, que geralmente são impraticáveis em cenários do mundo real. Por outro lado, o aprendizado

não supervisionado oferece uma alternativa útil ao permitir o agrupamento e a detecção de anomalias sem dados rotulados. Considerando essas características e desafios, este trabalho propõe explorar um estudo de caso em SHM, focado na avaliação de diferentes métodos de aprendizado supervisionado para quantificar distintos níveis de dano em paredes.

6.3 Trabalhos Relacionados

Os avanços tecnológicos das últimas décadas possibilitaram a incorporação de diversos tipos de sensores nos *smartphones*, tais como os acelerômetros, que permitem a medição precisa de variações de aceleração em diferentes eixos. Com isso, tais dispositivos começaram a ser explorados como uma alternativa viável para instrumentação em investigações de SHM baseadas em vibração. Essa abordagem apresenta vantagens como a portabilidade, o baixo custo e a facilidade de implementação em comparação com sistemas tradicionais de monitoramento, permitindo a coleta de dados estruturais de forma mais acessível e distribuída.

Diante desse cenário, Feng et al. (2015) examinaram a viabilidade de monitorar a vibração estrutural sob cargas típicas e altas usando acelerômetros de *smartphones*. Experimentos de mesa vibratória foram realizados para comparar os sensores desses dispositivos com acelerômetros de alta qualidade para detectar a vibração em várias frequências. Por fim, os autores também investigaram o desempenho dos sensores de *smartphones* em uma ponte real para pedestres construída em concreto reforçado pré-tensionado em Princeton (EUA). Kang, Baek e Park (2023) usaram um aplicativo de *smartphone* (*i-Jishin*) para estimar a grande deformação de um edifício de dois andares com uma estrutura RC preenchida com alvenaria e o desempenho das características dinâmicas. Foi realizada uma comparação com as leituras fornecidas por um acelerômetro de referência. Figueiredo et al. (2022) usaram o aplicativo *App4SHM* para detectar anomalias em duas estruturas: (i) vigas de aço de laboratório e (ii) duas pontes gêmeas de concreto pós-tensionado. O aplicativo coletou dados de vibração das estruturas usando os sensores internos do *smartphone* e, em seguida, estimou as frequências naturais da estrutura. Por fim, a avaliação de danos foi realizada comparando os dados adquiridos com os obtidos no cenário de referência.

Da mesma forma, Sun (2023) propôs o uso de instrumentação baseada em *smartphone* para monitorar a integridade estrutural das paredes em construções modernas. Nesse caso, o dispositivo desempenha a função de atuador e sensor. A estrutura é estimulada pela vibração do aparelho celular em uma determinada frequência, e as respostas dinâmicas são capturadas por seus sensores internos de acelerômetro e giroscópio. Avaliações realizadas quanto a influência da utilização de diferentes modelos de dispositivos, bem como aspectos relacionados à forma e à

direção em que os aparelhos são mantidos durante o monitoramento concluíram que estes fatores não tiveram um impacto significativo no desempenho do sistema.

Como primeiro experimento, Sun (2023) usou dados do eixo-Z do acelerômetro e do giroscópio do dispositivo. Os sinais foram submetidos a um processo de extração de tanto de atributos estatísticos quanto de Coeficientes Cepstrais de Mel-Frequência (*Mel-Frequency Cepstral Coefficients – MFCC*) (Abdul; Al-Talabani, 2022), que, por sua vez, foram submetidos aos modelos Floresta Aleatória (*Random Forest – RF*), Árvore de Decisão (*Decision Tree – DT*) e K-Vizinhos mais Próximos (*K-Nearest Neighbors – KNN*) (Shalev-Shwartz; Ben-Davis, 2014), para prever a condição estrutural das paredes: íntegra ou danificada. Posteriormente, o autor também avaliou a gravidade do dano interno em paredes conforme três níveis de profundidades de rachaduras: 2 mm, 4 mm e 6 mm. Entretanto, apesar dos bons resultados alcançados em tal trabalho, os modelos de aprendizado de máquina foram avaliados sob a perspectiva de dois sensores (acelerômetro e giroscópio) dos aparelhos.

Considerando que o uso de giroscópio no monitoramento estrutural é uma abordagem incomum e que a avaliação de sinais de acelerômetro é uma abordagem robusta e amplamente utilizada, Boratto et al. (2025a) utilizaram-se apenas de sinais de acelerômetro para avaliar um método de aprendizagem não-supervisionada no contexto de detecção de anomalias e quantificação dos danos nas paredes. Posteriormente, Boratto et al. (2025b) realizaram uma avaliação supervisionada para a detecção de danos nas paredes, propondo melhorias ao trabalho de referência (Sun, 2023). No entanto, em tal artigo, os autores não avaliaram o contexto de classificação quanto à severidade dos danos. Sendo assim, inspirados nestes trabalhos, o presente capítulo adota uma abordagem supervisionada que visa classificar os danos presentes nas paredes quanto a diferentes níveis de severidades por meio de atributos espectrais extraídos de leituras de acelerômetros de *smartphones*. Para isso, três modelos de aprendizado de máquina otimizados pelo método de busca em grade (*Grid Search*) foram utilizados: *Random Forest*, *Decision Tree* e *K-Nearest Neighbors*.

6.4 Material e Métodos

Esta seção detalha o conjunto de dados utilizado e apresenta uma visão geral dos modelos de aprendizado de máquina aplicados.

6.4.1 Conjunto de Dados

Sun (2023) implantou um aplicativo (*Vibwall*) para *smartphones* para registrar a resposta ao estímulo da vibração de um *smartphone* sobre a perspectiva de seu acelerômetro e giroscópio. As vibrações de excitação foram configuradas em cinco frequências distintas (10 Hz, 20 Hz, 30 Hz, 40 Hz e 50 Hz). Para avaliar a severidade

dos danos, o autor construiu uma parede de tijolos com dimensões de 1,6 m x 0,85 m x 0,20 m, possibilitando reproduzir diferentes cenários de danos, representados por rachaduras de três níveis de profundidades: 2 mm, 4 mm e 6 mm.

Um total de 100 amostras para o caso sem danos e 50 amostras para cada classe de dano foram geradas, totalizando 250 amostras, contendo as respostas dinâmicas resultantes das 5 frequências de excitação. Adicionalmente, o sensor foi configurado com uma taxa de amostragem de 100 Hz e cada estímulo de vibração foi aplicado por aproximadamente 6 segundos, resultando em sinais com um comprimento em torno de 600 pontos. Vale ressaltar que os sinais amostrados com uma quantidade maior de pontos foram truncados, visando padronizar a duração de todos eles nos 6 segundos. Posteriormente, o pacote *Time Series Feature Extraction Library (TSFEL)* (Barandas et al., 2020) foi utilizado para extrair 12 atributos espectrais, detalhados na Tabela 1, de cada sinal. Assim, combinando as diferentes frequências de estímulo para a mesma amostra, a matriz de atributos formada passou a apresentar 250 linhas (3 níveis de danos de gravidade diferentes x 50 testes dinâmicos + 100 testes de condições não danificadas) e 60 colunas (12 atributos x 5 frequências de excitação). Por fim, os atributos foram linearmente normalizados em [0, 1].

Tabela 1 – Conjunto de atributos espectrais extraídos dos sinais via TSFEL

Atributo	Descrição
A1	Centroide espectral
A2	Decremento da amplitude espectral
A3	Distância espectral
A4	Entropia espectral
A5	Curtose espectral
A6	<i>Roll-off</i> espectral
A7	Assimetria espectral
A8	Espalhamento espectral
A9	Densidade máxima do espectro de potência
A10	Frequência máxima
A11	Frequência mediana
A12	Largura de banda da densidade do espectro de potência

Fonte: Autores.

6.4.2 Modelos de Aprendizado de Máquina

6.4.2.1 *k*-Vizinhos mais Próximos (*k*-Nearest Neighbors, KNN)

Esse modelo de aprendizado de máquina classifica uma amostra de teste não rotulada com base na classe majoritária de seus vizinhos mais próximos. Esse processo envolve o cálculo das distâncias entre as amostras de teste e de treinamento usando

uma medida de distância específica (Liao; Vemuri, 2002). O KNN é reconhecido por sua simplicidade e eficácia na solução de vários problemas de classificação, demonstrando sua adaptabilidade a diferentes tipos de dados. Sua simplicidade está no fato de que o modelo não exige um processo de treinamento explícito. Isso significa que a fase de treinamento é praticamente inexistente, pois o KNN simplesmente armazena os dados de treinamento e só realiza cálculos intensivos durante a fase de classificação (Guo et al., 2003).

No entanto, é importante reconhecer suas desvantagens, como o desafio de determinar o valor ideal de k , que representa o número de vizinhos a serem considerados. Valores muito pequenos de k podem resultar em um modelo sensível ao ruído nos dados, enquanto valores muito grandes podem diluir a influência de vizinhos próximos relevantes (Abu Alfeilat et al., 2019). A alta carga computacional é outro desafio, pois o KNN exige o cálculo das distâncias de cada amostra de teste de todas as amostras de treinamento, o que pode ser inviável para grandes conjuntos de dados. Além disso, o KNN requer uma quantidade considerável de memória para armazenar todos os dados de treinamento, o que pode ser um fator limitante em aplicativos de grande escala.

A operação do algoritmo KNN baseia-se em duas fases principais. Durante o treinamento, as amostras e seus rótulos de classe são armazenados, garantindo que não haja dados ausentes ou não numéricos. Na fase de classificação, cada amostra de teste é classificada com base em um voto majoritário entre seus vizinhos mais próximos. As distâncias entre a amostra de teste e todas as amostras de treinamento são calculadas usando uma função de distância predefinida, como a distância euclidiana, e a classe que ocorre com mais frequência entre os vizinhos mais próximos de k é atribuída à amostra de teste. Essa abordagem garante que a amostra de teste seja classificada com precisão com base nos dados de treinamento mais relevantes e próximos (Abu Alfeilat et al., 2019). Além disso, também é possível definir uma função de peso (*weight*) usada para previsão, como peso uniforme, em que todos os pontos em cada vizinhança são ponderados igualmente, e peso por distância, em que os pontos de peso são ponderados pelo inverso de sua distância (Dudani, 1976).

6.4.2.2 *Árvore de Decisão (Decision Tree)*

O objetivo principal da árvore de decisão é construir um modelo que preveja a variável-alvo inferindo regras de decisão simples a partir dos recursos de dados, funcionando efetivamente como aproximações constantes por partes. Cada nó interno da árvore representa um teste em um recurso, cada ramo corresponde ao resultado do teste e cada nó folha representa um valor previsto da variável-alvo. Essa estrutura permite que as árvores de decisão aproximem funções como uma

curva senoidal por meio de uma série de regras *if-then-else*, em que árvores mais profundas produzem regulamentações mais complexas e um modelo ajustado com mais precisão (Safavian; Landgrebe, 1991).

Além disso, implementações computacionais deste modelo, como a disponível pela biblioteca *scikit-learn* (Pedregosa et al., 2011) do *Python*, permitem ajustar o comportamento do modelo usando alguns parâmetros adicionais, como *splitter* e *criterion*. O primeiro deles é um parâmetro relacionado à estratégia usada para escolher a divisão em cada nó; por exemplo, selecionar a melhor divisão em cada nó (*better*) ou selecionar um subconjunto aleatório de recursos e, em seguida, a melhor divisão desse subconjunto (*random*). O parâmetro *criterion* determina a função usada para medir a qualidade de uma divisão (Pedregosa et al., 2011). Essas opções oferecem flexibilidade para adaptar a árvore a conjuntos de dados e tarefas específicas, o que pode melhorar o desempenho e a generalização.

Um dos principais pontos fortes das árvores de decisão é sua versatilidade, o que as torna uma opção segura para uma ampla gama de tarefas de análise de dados. Sua representação visual intuitiva facilita o entendimento e a interpretação, permitindo uma maior compreensão do processo de tomada de decisão sem a necessidade de um amplo conhecimento técnico. Ao contrário de outros métodos de aprendizado de máquina, as árvores de decisão exigem uma preparação mínima dos dados, eliminando a necessidade de normalização extensiva dos dados e de manipulação de valores ausentes. Eles podem lidar com dados numéricos e categóricos de forma eficiente, tornando-os aplicáveis em diversos contextos. Além disso, o custo computacional de fazer previsões com este modelo é logarítmico em relação ao número de pontos de dados de treinamento, garantindo eficiência mesmo com grandes conjuntos de dados. As árvores de decisão também são compatíveis com problemas de múltiplas saídas, e sua transparência como modelo de caixa branca garante que seu processo de tomada de decisão seja totalmente interpretável. Os testes estatísticos podem validar esses modelos, garantindo a confiabilidade mesmo quando as suposições subjacentes são parcialmente violadas (Breiman, 2017).

Apesar dessas vantagens, as árvores de decisão tendem a se ajustar demais aos dados, especialmente quando a árvore é profunda. Esta limitação leva a uma generalização ruim para dados não vistos. Outra desvantagem significativa é sua instabilidade; pequenas variações nos dados podem levar a árvores substancialmente diferentes, tornando-as sensíveis a ruídos. A natureza constante por partes deste modelo limita seu desempenho em tarefas que exigem extrapolação além do intervalo dos dados de treinamento. Adicionalmente, as árvores de decisão apresentam dificuldades com padrões complexos como XOR (*exclusive OR*) e pode

produzir árvores tendenciosas se algumas classes dominarem o conjunto de dados, destacando a importância de equilibrar o conjunto de dados antes do treinamento (Safavian; Landgrebe, 1991).

6.4.2.3 Floresta Aleatória (Random Forest)

Uma maneira de reduzir o risco de ajuste excessivo é construir um conjunto de árvores de decisão, como no método Floresta Aleatória. Esse conjunto combina previsões de vários classificadores usando uma regra de decisão de voto majoritário para melhorar a robustez e a generalização do modelo (Shalev-Shwartz; Ben-David, 2014; Webb; Copsey; Cawley, 2011). A floresta aleatória compreende várias árvores de decisão, em que cada árvore individual é construída a partir de uma amostra aleatória do conjunto de dados, usando a técnica de *bagging* (agregação de *bootstrap*). Nesse processo, diferentes subconjuntos do conjunto de treinamento são gerados aleatoriamente com substituição, criando diversidade entre as árvores no modelo (Webb; Copsey; Cawley, 2011). Essa aleatoriedade é fundamental para reduzir a correlação entre as árvores e, conseqüentemente, reduzir a variância do modelo.

As árvores em um modelo de floresta aleatória são desenvolvidas usando subconjuntos aleatórios dos recursos disponíveis, selecionados em cada nó da árvore. Esse processo introduz ainda mais variação entre as árvores, aumentando a resistência do modelo contra o ajuste excessivo. Cada árvore vota independentemente na classe mais frequente para classificar um novo vetor de entrada. A classe que recebe o maior número de votos entre todas as árvores da floresta é a decisão final do classificador para uma instância de dados (Breiman, 2001; Pal, 2005).

Para construir uma árvore de decisão, neste modelo, é essencial escolher uma medida adequada da importância do recurso, como a impureza ou a entropia de Gini, para orientar a divisão dos nós. Além disso, o número de árvores a serem geradas (número de estimadores), a profundidade máxima das árvores e o número de recursos a serem considerados em cada divisão também são parâmetros que influenciam o desempenho do modelo. A escolha cuidadosa desses parâmetros pode melhorar a capacidade de generalização da floresta aleatória, especialmente em conjuntos de dados complexos ou de alta dimensão. Por fim, a floresta classifica cada nova instância de dados passando-a por todas as árvores e selecionando a classe com a maioria dos votos (Pal, 2005).

6.4.3 Busca em Grade

Uma abordagem de otimização de hiperparâmetros baseada em busca em grade combinada com validação cruzada estratificada, esta última sendo escolhida para garantir que cada uma das divisões mantivesse a proporção original das classes,

foi realizada. O processo foi realizado em 30 execuções independentes, considerando 5 divisões da validação cruzada. Para cada iteração, um novo conjunto de divisões de treinamento e teste foi gerado, garantindo a robustez dos resultados. Adicionalmente, o conjunto de treinamento é novamente particionado para reservar 25% de seus dados para a etapa de validação. Esse estágio é essencial para avaliar o desempenho dos diferentes hiperparâmetros durante o processo de busca em grade. Os detalhes dos parâmetros internos avaliados por este método são mostrados na Tabela 2.

Tabela 2 – Hiperparâmetros avaliados pelo processo de busca em grade

Modelo de Classificação	Hiperparâmetro	Candidatos
KNN	<i>n_neighbors</i>	[1, 2, 3, 5, 10, 50, 100]
	<i>weights</i>	[uniform, distance]
DT	<i>max_depth</i>	[2, 5, 10, 15]
	<i>criterion</i> <i>splitter</i>	[gini, entropy, log_loss] [best, random]
RF	<i>max_depth</i>	[2, 5, 10, 15]
	<i>n_estimators</i> <i>criterion</i>	[10, 50, 100, 200] [gini, entropy, log_loss]

Fonte: Autores.

O processo de busca em grade foi usado para explorar exaustivamente todas as combinações possíveis dos hiperparâmetros especificados. Para cada combinação, o modelo é treinado no conjunto de treinamento e avaliado no conjunto de validação. Após testar todas as combinações, a combinação que resulta no melhor desempenho no conjunto de validação é selecionada como a melhor. Esse processo é repetido para cada iteração de validação cruzada, e os melhores hiperparâmetros encontrados em cada iteração são armazenados para análise posterior.

6.5 Experimentos Computacionais

Para avaliar o desempenho do modelo de forma abrangente, os experimentos computacionais foram realizados 30 vezes usando diferentes divisões aleatórias dos dados por meio de uma validação cruzada estratificada com 5 divisões. Isso resultou em um total de 150 avaliações de modelos em várias partições de conjuntos de dados e sob a perspectiva de quatro métricas de desempenho: acurácia, precisão e *recall* e F1.


Os resultados obtidos pela execução dos três modelos de aprendizado de máquina estão mostrados na Tabela 3. Adicionalmente, as matrizes de confusão médias geradas para cada caso são apresentadas na Figura 1.

Tabela 3 – Desempenho médio e desvios-padrão (%) alcançado pelos modelos

Classificador	Acurácia	Precisão	Recall	F1
KNN	99,08 (1,40)	98,99 (1,62)	98,86 (1,98)	98,85 (1,89)
DT	97,57 (3,62)	96,89 (7,74)	97,02 (7,20)	96,80 (6,87)
RF	99,21 (1,20)	99,11 (2,40)	99,02 (2,27)	99,02 (1,87)

Fonte: Autores.

Figura 1 – Matriz de confusão média obtida por cada caso. (a) KNN. (b) DT. (c) RF




Fonte: Autores.

Ao avaliar os resultados apresentados quanto às métricas de desempenho, é possível perceber que o modelo RF obteve desempenho médio superior aos modelos KNN e DT. No entanto, a diferença entre RF e KNN não parece ser estatisticamente significativa. Para confirmar essa hipótese, foi realizado um teste ANOVA, que corroborou a ausência de diferença estatisticamente significativa entre os desempenhos dos modelos KNN e RF em todas as métricas avaliadas. Além disso, o KNN apresentou os menores desvios-padrão para Precisão e *Recall*, enquanto para a métrica F1, o desvio-padrão foi semelhante ao do RF. Já em termos de acurácia, o RF apresentou o menor desvio-padrão.

A análise das matrizes de confusão revela que, em todos os modelos, o dano 1 (2 mm) teve os maiores erros de classificação, sendo erroneamente identificado como dano de severidade 2 (4 mm) em 4,47%, 5,50% e 1,67% dos casos nos modelos KNN, DT e RF, respectivamente. O último modelo, por sua vez, apresentou uma taxa de confusão similar (1,53%), classificando amostras de vibração referentes à classe dano 2, como sendo da classe dano 3 (6 mm). Por outro lado, os maiores acertos de classificação ocorreram para as estruturas íntegras, exceto no modelo KNN, onde o dano 3 teve a maior taxa de acerto. Ainda assim, a estrutura íntegra apresentou um desempenho semelhante, com 99,97% de acerto.


Com relação aos parâmetros internos dos modelos selecionados pelo processo de busca em grade durante a execução do modelo, verificou-se que a profundidade máxima das árvores no modelo RF (*max_depth*) foi unanimemente escolhida como sendo 5 níveis, e o ajuste *uniform* do parâmetro de pesos (*weights*) para o modelo KNN também foi escolhido unanimemente. Quanto aos demais parâmetros, as Figuras 2, 3 e 4 mostram a frequência com que cada ajuste foi selecionado.

Figura 2 – Frequência de seleção dos parâmetros do modelo RF realizadas pelo processo de busca em grade

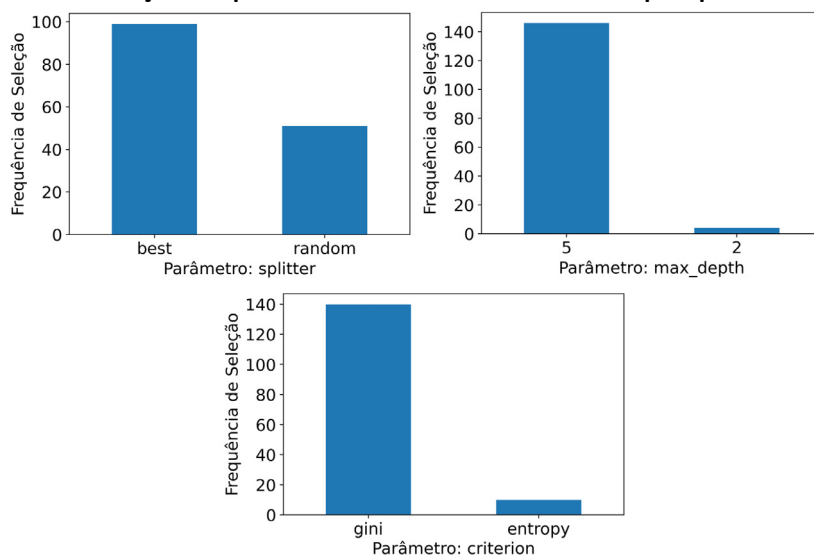


Fonte: Autores.

Figura 3 – Frequência de seleção dos parâmetros do modelo KNN realizadas pelo processo de busca em grade



Fonte: Autores.

Figura 4 – Frequência de seleção dos parâmetros do modelo DT realizadas pelo processo de busca em grade

Fonte: Autores.

Conforme ilustrado nas Figuras 2, 3 e 4, para o modelo RF, o critério *gini* foi selecionado em 144 das 150 iterações, enquanto *entropy* apareceu em apenas 6. Quanto ao número de estimadores, 10 foi a escolha mais frequente, selecionado em 104 iterações, seguido por 50 estimadores em 38 iterações. As opções de 100 e 200 estimadores foram escolhidas apenas 4 vezes. Para o modelo KNN, a busca em grade indicou que $n_neighbors = 1$ foi a melhor configuração em 110 iterações, seguido por 2 vizinhos em 36 iterações, 3 vizinhos em 3 iterações e 50 vizinhos em apenas 1 iteração. No modelo DT, o critério *gini* também predominou, sendo escolhido em 140 iterações, enquanto *entropy* foi selecionado apenas 10 vezes. A profundidade máxima de 5 níveis foi definida em 146 iterações, enquanto 2 níveis foram escolhidos apenas 4 vezes. Quanto ao parâmetro *splitter*, a opção “best” foi utilizada em 99 iterações, enquanto *random* foi selecionada em 51.

Portanto, de forma geral, percebe-se que para os modelos baseados em árvore, houve uma convergência na escolha pela profundidade máxima das árvores em 5 níveis, bem como a utilização do critério *gini* para medir a qualidade da divisão. Adicionalmente, um ajuste com uma menor quantidade de vizinhos é preferível para ser utilizado pelo KNN, bem como uma quantidade reduzida de estimadores para o RF.

6.6 Considerações Finais

Nesta seção, propusemos a utilização de atributos espectrais como recursos para modelos de aprendizado de máquina para quantificar a severidade de danos em paredes quanto a três níveis, usando apenas dados de acelerômetro de *smartphones*. Os modelos de aprendizado de máquina avaliados conseguiram atingir resultados

promissores, que podem ser consequência de uma série de fatores, como por exemplo da qualidade dos dados, uma vez que foram obtidos sob uma supervisão e não representam exatamente um cenário real em que se tem uma variação das paredes e dos danos propriamente ditos. Adicionalmente, a otimização dos hiperparâmetros dos modelos combinada com a validação cruzada permitiu que os modelos tivessem um desempenho melhor, especialmente o RF. Isso indica que o modelo proposto poderia atenuar possíveis efeitos de sobreajuste.

Aliado aos resultados promissores obtidos, a proposta de empregar sensores acessíveis, como acelerômetros integrados em *smartphones*, combinados com técnicas de aprendizado de máquina para analisar dados espectrais oferece um potencial significativo para reduzir custos e facilitar a coleta de dados em campo, destacando a viabilidade de aplicações em larga escala. Nesse sentido, a integração dos modelos propostos em aplicativos móveis pode facilitar a automação do processo de detecção, permitindo que os usuários realizem avaliações em tempo real de maneira prática e eficiente.

6.7 Agradecimentos

Os autores agradecem à agência de fomento brasileira CAPES — Código Financeiro 001 pelo apoio financeiro. Agradecemos também o apoio fornecido pelo CNPq, FAPEMIG e UFJF, e ao grupo de pesquisa CIDENG-CNPq.

6.8 Referências

ABDUL, Z. K.; AL-TALABANI, A. K. Mel frequency cepstral coefficient and its applications: a review. **IEEE Access**, [S.l.], v. 10, p. 122.136-122.158, 2022.

ABU ALFEILAT, H. A. et al. Effects of distance measure choice on K-nearest neighbor classifier performance: a review. **Big Data**, [S.l.], v. 7, n. 4, p. 221-248, 2019. [S.l.]: Mary Ann Liebert Inc. DOI: <https://doi.org/10.1089/big.2018.0175>.

ALVES, V.; CURY, A. An automated vibration-based structural damage localization strategy using filter-type feature selection. **Mechanical Systems and Signal Processing**, [S.l.], v. 190, p. 110.145, 2023. DOI: <https://doi.org/10.1016/j.ymssp.2023.110145>.

AVCI, O. et al. A review of vibration-based damage detection in civil structures: from traditional methods to Machine Learning and Deep Learning applications. **Mechanical Systems and Signal Processing**, [S.l.], v. 147, p. 107.077, 2021. DOI: <https://doi.org/10.1016/j.ymssp.2020.107077>.

BARANDAS, M. et al. TSFEL: Time Series Feature Extraction Library. **SoftwareX**, [S.l.], v. 11, p. 100.456, 2020.

BORATTO, T. et al. An agglomerative clustering combined with an unsupervised feature selection approach for structural health monitoring. **Infrastructures**, [S.l.], v. 10, p. 32, 2025a. DOI: <https://doi.org/10.3390/infrastructures10020032>.

BORATTO, T. et al. On the use of spectral data from smartphone accelerometer signals and constituent material for the identification of damaged walls. **Revista de Informática Teórica e Aplicada**, [S.l.], v. 32, n. 2, p. 52-63, 2025b. DOI: <https://doi.org/10.22456/2175-2745.142129>.

BREIMAN, L. Random forests. **Machine Learning**, Dordrecht, v. 45, n. 1, p. 5-32, 2001. DOI: <https://doi.org/10.1023/A:1010933404324>.

BREIMAN, L. **Classification and regression trees**. [S.l.]: Routledge, 2017.

CHEN, Z. et al. Sensor data-driven structural damage detection based on deep convolutional neural networks and continuous wavelet transform. **Applied Intelligence**, [S.l.], v. 51, n. 8, p. 5.598-5.609, 2021.

DUDANI, S. A. The distance-weighted k-nearest-neighbor rule. **IEEE Transactions on Systems, Man, and Cybernetics**, [S.l.], v. SMC-6, n. 4, p. 325-327, 1976. DOI: <https://doi.org/10.1109/TSMC.1976.5408784>.

FARRAR, C. R.; WORDEN, K. An introduction to structural health monitoring. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 365, n. 1851, p. 303-315, 2007. DOI: <https://doi.org/10.1098/rsta.2006.1928>.

FENG, M.; FUKUDA, Y.; MIZUTA, M.; OZER, E. Citizen sensors for SHM: use of accelerometer data from smartphones. **Sensors**, [S.l.], v. 15, n. 2, p. 2.980-2.998, 2015.

FIGUEIREDO, E. et al. Smartphone application for structural health monitoring of bridges. **Sensors**, [S.l.], v. 22, n. 21, art. 8.483, 2022.

GUO, G. et al. KNN model-based approach in classification. In: MEERSMAN, R.; TARI, Z.; SCHMIDT, D. C. (Org.). **On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE**. Berlim, Heidelberg: Springer, p. 986-996, 2003.

KANG, J.-D.; BAEK, E.-R.; PARK, S.-H. Evaluation of vibration detection using smartphones in a two-story masonry-infilled RC frame building. **Buildings**, [S.l.], v. 13, n. 4, art. 1.069, 2023.

KAUSS, K. et al. Semi-supervised structural damage assessment via autoregressive models and evolutionary optimization. **Structures**, [S.l.], v. 59, p. 105.762, 2024.

LIAO, Y.; VEMURI, V. R. Use of k-nearest neighbor classifier for intrusion detection. **Computers & Security**, [S.l.], v. 21, n. 5, p. 439-448, 2002.

PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, Londres, v. 26, n. 1, p. 217-222, 2005.

PEDREGOSA, F. et al. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, [S.l.], v. 12, p. 2.825-2.830, 2011.

RYTTER, A. **Vibrational based inspection of civil engineering structures**. 1993. Tese (Doutorado em Engenharia Civil) – Aalborg University, Aalborg. Dinamarca, 1993.

SAFAVIAN, S. R.; LANDGREBE, D. A survey of decision tree classifier methodology. **IEEE Transactions on Systems, Man, and Cybernetics**, [S.l.], v. 21, n. 3, p. 660-674, 1991.

SARMADI, H.; ENTEZAMI, A.; GHALEHNOVI, M. On model-based damage detection by an enhanced sensitivity function of modal flexibility and LSMR-Tikhonov method under incomplete noisy modal data. **Engineering with Computers**, [S.l.], v. 38, n. 1, p. 111-127, 2020.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. Understanding machine learning: from theory to algorithms. Cambridge, USA: Cambridge University Press, 2014.

SUN, W. VibWall: smartphone's vibration challenge-response for wall crack detection. **ACM Journal of Computing for Sustainable Society**, Nova York, v. 1, n. 1, art. 5, 2023.

XU, N.; ZHANG, Z.; LIU, Y. Spatiotemporal fractal manifold learning for vibration-based structural health monitoring. In: YUAN, F.-G. (Org.). **Structural Health Monitoring/ Management (SHM) in Aerospace Structures**. Cambridge: Woodhead Publishing, p. 409-426, 2024. (Woodhead Publishing Series in Composites Science and Engineering). DOI: <https://doi.org/10.1016/B978-0-443-15476-8.00017-4>.

WEBB, A. R.; COPSEY, K. D.; CAWLEY, G. **Statistical pattern recognition**. 3. ed. Hoboken, NJ: Wiley-Blackwell, 2011.

6.9 Sobre os(as) autores(as)

Tales Humberto de Aquino Boratto possui graduação em Ciências Exatas (2019) e em Engenharia Mecânica (2020) e mestrado em Modelagem Computacional pela Universidade Federal de Juiz de Fora. Atualmente é doutorando pelo programa de pós-graduação em modelagem computacional da UFJF. Tem experiência na área de ciência de dados e machine learning, especialmente aplicada a contextos de engenharias.

Heder Soares Bernardino é graduado em Ciência da Computação (2006), mestre em Modelagem Computacional (2008) e doutor em Modelagem Computacional (2012) pela UFJF e LNCC/MCTI. É professor no Departamento de Ciência da Computação da UFJF e membro dos Programas de Pós-graduação em Modelagem Computacional e Ciência da Computação. Sua pesquisa foca em Inteligência Computacional, com ênfase em descoberta de conhecimento e otimização, aplicados à saúde e engenharias. É membro do SIGEVO da ACM, IEEE, IEEE Computational Intelligence Society e chair da IEEE Task Force on Nature-Inspired Constrained Optimization.

Alexandre Abrahão Cury é Engenheiro Civil pela UFJF, mestre em Modelagem Computacional pela mesma instituição e doutor em Engenharia Civil pela École Nationale des Ponts et Chaussées. Suas pesquisas abordam monitoramento de integridade estrutural, machine learning e confiabilidade estrutural. Foi coordenador do PPG em Engenharia Civil da UFJF e membro da Câmara de Assessoramento de Arquitetura e Engenharias da FAPEMIG e da Comissão de Avaliação das Engenharias I da CAPES (2017-2021). É pesquisador de Produtividade do CNPq desde 2013, membro do Comitê de Assessoramento do CNPq e editor de Build Engineering e Structural Sensing.

Leonardo Goliatt é graduado em Engenharia Civil pela UFJF (2003) e doutor em Modelagem Computacional pelo LNCC (2009). Foi professor da UFES (2010) e é professor associado do Departamento de Mecânica Aplicada e Computacional e membro permanente do Programa de Pós-Graduação em Modelagem Computacional da UFJF. Atuou como chefe do departamento (2014-2016) e presidente da Comissão Própria de Avaliação da UFJF (2022-2024). Coordenou o PPGMC da UFJF (2018-2021) e os programas de pesquisa da Pró-reitoria de Pós-graduação e Pesquisa (2022-atual). Sua pesquisa foca em Inteligência Artificial e Ciência de Dados.

7 AVALIAÇÃO DE DANOS ESTRUTURAIS UTILIZANDO OTIMIZAÇÃO INTEIRA MISTA VIA CLASSIFICAÇÃO

Yan Messias de Azevedo Fonseca¹, Carlos Cristiano Hasenclever Borges¹

¹Departamento de Ciência da Computação - Universidade Federal de Juiz de Fora.

7.1 Resumo

O desenvolvimento contínuo dos métodos de Aprendizagem de Máquina e Inteligência Computacional, áreas da Inteligência Artificial, tem proporcionado o desenvolvimento de novas ferramentas para o tratamento de problemas complexos que se apresentam em diversas linhas das engenharias. A Inteligência Computacional tem fornecido valiosas ferramentas de otimização principalmente pelos bem estabelecidos algoritmos bio-inspirados. Especificamente, a adaptação de métodos de aprendizado indutivo para problemas de otimização ainda está em seus primeiros passos. Nessa linha, apresenta-se uma estratégia baseada em aprendizado supervisionado para a avaliação de dano estrutural em estruturas reticulares discretizadas usando o Método dos Elementos Finitos. Baseando-se em funções objetivo, construídas com dados vibracionais da estrutura sem danos e danificada, propõe-se um modelo hierárquico via otimização inteira mista com potencial para avaliação qualitativa e quantitativa do dano. Experimentos numéricos em diversos tipos de estruturas reticulares são realizados visando determinar o modelo de otimização via classificação desenvolvido para essa classe de problemas inversos em engenharia estrutural.

Palavras-Chave: Otimização por Classificação; Aprendizagem de Máquina; Método dos Elementos Finitos; Análise Modal

7.2 Introdução

Os problemas de otimização em engenharia apresentam desafios como complexidade do espaço de busca, presença de variáveis inteiras e reais, restrições e dificuldade na obtenção de gradientes da função objetivo. Métodos baseados em Programação Matemática são eficazes para otimização convexa, mas limitados em problemas globais.

Alternativamente, meta-heurísticas evolutivas e métodos baseados em enxames (Mirjalili et al., 2023) têm sido amplamente utilizados, pois balanceiam exploração e exploração sem depender de derivadas, tornando-os adaptáveis a diferentes tipos de variáveis. Esses algoritmos, baseados na interação entre indivíduos de uma população, diferem dos métodos tradicionais que atualizam uma única solução inicial.

Mais recentemente, a Aprendizagem de Máquina tem sido aplicada à otimização baseada em modelos (Nezami; Anahideh, 2022), utilizando aprendizagem supervisionada para segmentar o espaço de busca em candidatos positivos e negativos. Essa abordagem inclui o uso de funções de aproximação (*surrogate*) e funções de aquisição para equilibrar exploração e exploração (Hennig; Schuler, 2012; Regis; Shoemaker, 2007; Dickson, 2014).

Outra vertente envolve a otimização baseada em classificadores, que utiliza modelos binários para definir regiões de busca. Apesar do potencial dessa abordagem, poucas aplicações foram documentadas na engenharia (Hashimoto et al., 2018).

Neste trabalho, o modelo de otimização proposto por Yang Yu (Yu et al., 2016) será estendido para um problema inverso de detecção de dano em estruturas reticulares. A abordagem hierárquica adotada segue modelos de detecção em duas etapas, onde a primeira identifica a localização do dano e a segunda quantifica sua magnitude. O estudo inclui modelagem via elementos finitos, definição das funções objetivo e experimentação em diferentes configurações estruturais.

7.3 Dados vibracionais na detecção de dano em estruturas

A análise vibracional de estruturas, desempenha um papel essencial na avaliação da segurança de estruturas sujeitas a carregamentos dinâmicos e na garantia de um nível adequado de conforto em relação às vibrações durante seu uso. Esse tipo de análise não apenas ajuda a prever o comportamento dinâmico das estruturas, mas também é vital para a detecção de danos estruturais, que podem ocorrer devido ao desgaste ao longo do tempo ou a carregamentos inesperados.

Os modelos de detecção de danos estruturais são geralmente construídos com base em dados vibracionais coletados tanto de estruturas intactas quanto danificadas,

esses dados funcionam como uma impressão digital da estrutura (Doebbling et al., 1996). A presença de danos é tipicamente caracterizada pela perda de rigidez em uma ou mais regiões da estrutura, o que se reflete diretamente nas frequências naturais e modos de vibração observados nos dados vibracionais. Para simular o comportamento da estrutura são utilizadas estratégias numéricas de discretização, permitindo a criação de um modelo analítico detalhado.

No campo da engenharia civil e mecânica, os métodos numéricos são cruciais para o desenvolvimento de estruturas confiáveis. Entre esses métodos, o Método dos Elementos Finitos (MEF) (Zienkiewicz et al., 2000) se destaca devido ao seu amplo suporte matemático e significativo desenvolvimento experimental. Este método permite a modelagem detalhada de estruturas complexas e a análise de seu comportamento sob várias condições de carga. Também é bastante eficiente na obtenção dos dados vibracionais de estruturas e construção de modelos para detecção de danos (Alkayem et al., 2017).

7.4 Modelagem analítica de dano em estruturas reticulares

Quando se trata de estruturas danificadas, o dano é modelado introduzindo-se uma variável indicadora de dano em cada elemento, refletindo o nível de perda de rigidez. Essa abordagem envolve a manipulação algébrica de modelos sem danos e danificados, juntamente com dados vibracionais experimentais, para obter parâmetros de dano com a precisão necessária. No entanto, esse é um problema inverso, muitas vezes mal condicionado e geralmente sem solução única.

7.4.1 Modelagem do dano

Durante o processo de montagem dos elementos finitos, as variáveis indicadoras de dano local tendem a influenciar os diversos elementos conectados por nós a partir de suas matrizes de rigidez, o que pode dificultar a identificação precisa da localização e extensão do dano. Esse desafio adicional requer técnicas avançadas de processamento de dados e modelagem para garantir que os modelos resultantes sejam suficientemente precisos para uso prático na detecção e avaliação de danos estruturais.

A equação de vibração livre para os estados não danificado e danificado da estrutura são dadas, respectivamente, por Borges et al. (2007):

$$(K^u - \lambda_i^u M)\phi_i^u = 0$$

$$(K^d - \lambda_i^d M)\phi_i^d = 0$$

onde se assume que o dano afeta apenas a matriz de rigidez K , deixando a matriz de massa M inalterada.

A matriz de rigidez do j -ésimo elemento danificado é modelada como:

$$K_i^d = \alpha_i K$$

onde o escalar α_j define a redução na matriz de rigidez do elemento. A matriz global de rigidez é expressa como:

$$K = A_{j=1}^{n_{ele}} K_j$$

onde A denota o operador de montagem utilizado no método dos Elementos Finitos.

7.4.2 Funções objetivo

A identificação de danos a partir de análises modais pode ser realizada utilizando diferentes funções objetivo baseadas em medidas experimentais e computacionais. A energia de deformação modal (*MSE - Modal Strain Energy*) e o critério de garantia modal (*MAC - Modal Assurance Criterion*) são frequentemente empregados para avaliar as discrepâncias entre os modos vibracionais da estrutura real e os modos simulados por modelos computacionais (Alkayem; Cao, 2018).

A primeira função objetivo, f_1 , baseia-se na diferença absoluta entre o MSE da estrutura medida e o MSE da estrutura gerada pelo algoritmo:

$$f_1 = \sum_{i=1}^n \left| \frac{1}{2} (\phi_i^M)^T K_i (\phi_i^M) - \frac{1}{2} (\phi_i^G)^T K_i (\phi_i^G) \right|$$

A segunda função objetivo, f_2 , refina os valores obtidos por f_1 ao introduzir uma penalização baseada no ângulo entre os modos de vibração da estrutura medida e da estrutura gerada:

$$f_2 = f_1 * \sum_{i=1}^n \arccos \left(\frac{\phi_i^M \phi_i^G}{\|\phi_i^M\| * \|\phi_i^G\|} \right)$$

A terceira função objetivo, f_3 , também se baseia na função f_1 , mas incorpora uma penalidade baseada na função MAC:

$$f_3 = f_1 * (1 - MAC(\phi^M, \phi^G))$$

onde:

$$MAC = \sum_{i=0}^n \frac{((\phi_i^M)^T * \phi_i^G)^2}{((\phi_i^M)^T * \phi_i^M) * ((\phi_i^G)^T * \phi_i^G)}$$

7.5 Otimização via classificação

O uso de meta-heurísticas evolutivas para a detecção de danos em estruturas é uma linha razoavelmente bem estabelecida na literatura (Borges et al., 2007; Alkayem et al., 2017), sendo que modelos baseados em otimização por classificação ainda não foram utilizados para tal propósito. A implementação de um algoritmo baseado em otimização por classificação (Yu et al., 2016) foi a base para o desenvolvimento do modelo de identificação de dano desenvolvido. Pode-se descrever o seu funcionamento da seguinte forma: Inicialmente, soluções são geradas aleatoriamente e organizadas em um conjunto. Este conjunto é ordenado de acordo com os valores de uma função objetivo, de modo que as melhores soluções são colocadas em um conjunto positivo, representando os melhores valores encontrados, enquanto as demais soluções são alocadas em um conjunto negativo.

A otimização prossegue com a seleção aleatória de uma solução positiva e uma negativa. Em seguida, certos valores dessas soluções são comparados aleatoriamente em diversas dimensões. Dessa comparação é gerada uma nova solução. Este processo se repete, gerando sucessivos conjuntos de soluções. O ciclo de iterações continua até que se obtenha um conjunto final de valores próximos ao valor desejado.

Figura 1 – Pseudocódigo referente ao algoritmo

Algorithm 1 Otimização Baseada em Classificação

1: Entrada: $fct, samplesize, iteration$	▷ Função objetivo, tamanho da amostra, número de iterações
2: Saída: $Optimal$	▷ Melhor solução encontrada
3: $Pop \leftarrow inicializar()$	▷ Inicialização da população
4: $Popv \leftarrow fct(Pop)$	▷ Gerar população inicial
5: $PosPop \leftarrow selecionar\ melhores(Pop, Popv)$	▷ Avaliar população inicial
6: $Optimal \leftarrow \min(PosPop)$	▷ Selecionar melhores soluções
7: for $itera = 2$ to $iteration$ do	▷ Definir melhor solução inicial
8: for $i = 1$ to $samplesize$ do	
9: $ChosenPos \leftarrow amostra(PosPop)$	▷ Escolher uma solução positiva
10: $region \leftarrow ajustar\ limites(Pop, ChosenPos)$	▷ Ajustar região de busca
11: $NextPop(i) \leftarrow gerar\ candidato(region)$	▷ Gerar novo candidato
12: if $NextPop(i) \notin Pop$ then	▷ Garantir unicidade do candidato
13: $NextPopv(i) \leftarrow fct(NextPop(i))$	▷ Avaliar novo candidato
14: end if	
15: end for	
16: $Pop \leftarrow NextPop$	
17: $PosPop \leftarrow atualizar\ melhores(Pop, Popv)$	
18: if $Optimal > \min(PosPop)$ then	▷ Atualizar melhor solução encontrada
19: $Optimal \leftarrow \min(PosPop)$	
20: end if	
21: end for	

Fonte: Autores.

7.6 Um modelo hierárquico para detecção de dano

Nas seções anteriores, foram apresentados a conceituação do problema de dano estrutural, bem como sua representação analítica via MEF, funções objetivo usando equacionamento dinâmico (autovalores e autovetores da estrutura) e um otimizador baseado em classificação com potencial para a minimização das funções objetivo. A seguir, descreve-se a construção do modelo específico para detecção de dano em estruturas reticulares utilizando tais ferramentas.

A detecção de dano estrutural é um procedimento bastante complexo visto que se trata de um problema de otimização inverso. Desta forma algumas estratégias (Cury et al., 2010) dividem a busca do estado de danificação da peça estrutural em duas etapas, a saber (Doebbling et al., 1996):

- **Localização do dano:** determina quais elementos estruturais possuem danos (dano qualitativo).;
- **Quantificação do dano:** avalia a intensidade do dano identificado (dano quantitativo).

Tal estratégia é bastante interessante quando a primeira etapa consegue determinar adequadamente as posições da estrutura em que o dano se apresenta. No caso de estruturas reticulares, seriam determinadas as barras que devem apresentar algum nível de perda de rigidez. Feita corretamente a fase qualitativa, na etapa quantitativa, busca-se a perda de rigidez somente nas barras previamente identificadas como danificadas, permitindo, assim, uma diminuição do espaço de busca o que facilita o processo de otimização.

A utilização de um otimizador baseado em classificação tem como uma das vantagens o trato concomitante de variáveis discretas e variáveis reais, ou seja, é uma ferramenta que suporta otimização inteira mista. Essa característica do otimizador será utilizada para o desenvolvimento de um modelo específico de detecção de dano em duas etapas, o modelo será descrito a seguir.

Uma estratégia em duas etapas para localização e posterior quantificação do dano em estruturas será desenvolvida usando o otimizador via classificação por meio de um modelo hierárquico. O procedimento hierárquico, inicialmente, baseia-se na definição de duas variáveis para cada barra da estrutura reticular: (i) uma variável booleana (0 ou 1) associada ao processo de localização do dano nas barras; e, (ii) uma variável real entre $[0,1]$ indicando o nível de dano em cada barra onde: o valor 0 indica a barra 100% danificada e o valor 1 a barra sem dano. Assim, um valor de $\alpha_i = 0,8$ indica que a i -ésima barra apresenta um dano de 20%. Exemplificando, supondo uma estrutura com 4 barras, a codificação das variáveis da otimização inteira mista ficaria:

Tabela 1 – Modelo hierárquico: indica a i -ésima variável discreta e indica a i -ésima variável contínua

B_1	α_1	B_2	α_2	B_3	α_3	B_4	α_4
-------	------------	-------	------------	-------	------------	-------	------------

Fonte: Autores.

O uso direto dessa codificação mista usualmente apresenta conflito entre as variáveis mistas como, por exemplo, se para uma determinada barra tem-se os valores:

Tabela 2 - Exemplo de uso do sistema hierárquico para um elemento

1	0.9
---	-----

Fonte: Autores.

Tem-se o indicativo que a barra em questão não tem dano (pela variável booleana) e apresenta um dano de 10% pela variável real associada a barra. Ou seja, a combinação mista de variáveis não funciona de forma direta.

Assim, a construção do modelo em duas etapas de detecção de dano por meio da otimização inteira mista, é viabilizada por meio de uma estratégia hierárquica na forma:

- a variável booleana é a de maior nível hierárquico, ou seja, direciona o estado de danificação da barra;
- a variável real (α) só é ativada caso a variável booleana associada a barra indique que essa barra é danificada.


No caso do exemplo da barra anterior, apesar da variável indicar um dano de 10%, porém, a variável superior hierarquicamente indica que a barra não tem dano.

Deve-se ressaltar uma das vantagens do modelo hierárquico apresentado é a possibilidade das duas etapas de detecção de dano, a saber, localização e quantificação, serem feitas de forma simultânea pelo mesmo procedimento de otimização, contrário a maioria dos métodos da literatura (Cury et al., 2010).

7.7 Experimentos Numéricos


Os procedimentos experimentais fizeram uso das estruturas a seguir (escala em metros):

Figura 2 – Modelo de treliça plana utilizada




Fonte: Autores.

Figura 3 – Modelo de pórtico plano utilizado



Fonte: Autores.

Figura 4 – Modelo de viga utilizado



Fonte: Autores.

Para cada estrutura foi testado um cenário de dano específico, conforme apresentado abaixo. Além disso, o algoritmo foi executado 20 vezes para possibilitar uma análise estatística mais robusta.

- Treliça plana: dano de 50% na barra 5;
- Pórtico plano: dano de 50% na barra 9;
- Barra de Timoshenko: dano de 50% na barra 5.

Os parâmetros utilizados pelo algoritmo podem ser vistos na tabela a seguir.

Tabela 3 – Parâmetros utilizados no modelo

Quantidade de iterações	500
Tamanho do conjunto positivo	30
Tamanho do conjunto negativo	40
bits incertos	4

Fonte: Autores.

Os bits incertos servem para introduzir um grau de aleatoriedade controlada no processo de amostragem. Eles são usados para garantir que algumas dimensões do espaço de busca não sejam completamente fixadas e ainda possam variar de forma incerta, permitindo que a busca explore melhor o espaço de soluções.

7.8 Resultados

Os resultados experimentais referentes aos danos qualitativos (quantidade de erros na medida discreta) podem ser vistos nas tabelas 4, 5 e 6 abaixo.

Tabela 4 – Resultados das funções objetivo para o cenário da treliça plana

Função Objetivo	Média do erro	Desvio-padrão do erro
f1	3.3	0.9539
f2	2.5	1.4663
f3	0.2	0.6782

Fonte: Autores.

Tabela 5 – Resultados das funções objetivo para o cenário do pórtico plano

Função Objetivo	Média do erro	Desvio-padrão do erro
f1	4.7	1.3454
f2	5.3	1.6155
f3	2.95	1.9358

Fonte: Autores.

Tabela 6 – Resultados das funções objetivo para o cenário da viga


Função Objetivo	Média do erro	Desvio-padrão do erro
f1	3.95	1.1169
f2	2.95	1.2031
f3	1.4	1.4629

Fonte: Autores.

As tabelas indicam que o algoritmo utilizando a função objetivo sozinha não obtém grandes resultados qualitativos, sendo a função a função que obteve resultados mais promissores.

Os gráficos a seguir sintetizam os resultados obtidos, representados por *boxplots* para cada elemento de cada estrutura. Foram realizados testes preliminares com todas as funções objetivo, mas apenas os melhores resultados foram exibidos. A Figura 5 exibe os dados para a treliça, onde o método se mostrou altamente eficaz na identificação do dano na maioria dos casos.


Figura 5 – Gráfico Box-Plot da quantificação de dano para a treliça considerando a função f_3



Fonte: Autores.


A figura 6 apresenta os resultados para o pórtico, evidenciando uma boa performance na detecção de elementos danificados. A barra 10 teve metade dos dados concentrados em 0, e a ampla dispersão até o terceiro quartil sugere que esse seja o valor mais adequado.

Figura 6 – Gráfico Box-Plot da quantificação de dano para o pórtico considerando a função f_3



Fonte: Autores.

Por fim, a figura 7 exibe os resultados para a viga, que, assim como a treliça, obteve um desempenho excelente, com os dados do elemento 5 concentrados no valor de dano correto.

Figura 7 - Gráfico Box-Plot da quantificação de dano para a viga considerando a função f_3 

Fonte: Autores.

7.9 Considerações Finais

O uso de métodos de Aprendizagem de Máquina para problemas de otimização em engenharias, baseando-se no conceito de otimização fundamentada em modelos de classificação, tem apresentado seus primeiros protótipos nos anos recentes. Ancorando-se no conceito de classificação binária, com a inferência de instâncias positivas e negativas, que norteiam procedimentos de exploração e exploração do espaço de busca cruciais em problemas multimodais de otimização global.

O desafio torna-se ainda maior quando se trata de problemas inversos, normalmente mal postos e sem garantia de solução única. Nessa linha, o interesse maior do trabalho foi desenvolver e investigar o potencial de um modelo de otimização via classificação, específico para o problema de detecção de dano em estruturas reticulares discretizadas por meio do método dos Elementos Finitos.

Baseando-se em dados vibracionais da estrutura em seus estados sem danos e danificado, três funções objetivo foram construídas e testadas visando determinar a de maior sensibilidade na identificação e captura das variações dos dados vibracionais entre as estruturas.

A literatura indica que, dada a complexidade do problema de identificação de dano em estruturas, métodos em duas etapas, a saber, localização e posterior quantificação do dano costumam apresentar melhor desempenho. Nessa linha, desenvolveu-se um modelo hierárquico por meio da associação de duplas variáveis indicativas de dano por peça estrutural com uma variável inteira de maior nível hierárquico associada à presença do dano e uma variável real indicando a quantificação do mesmo, caso a variável inteira esteja ativada. O modelo hierárquico desenvolvido demanda, para sua resolução, um método para otimização inteira mista, construído.

Experimentos numéricos em diversas estruturas reticulares indicaram uma boa efetividade do modelo, conseguindo, na maioria das execuções, tanto a localização quanto a quantificação aproximada do dano nas barras.

Na sequência, é mandatório o aprimoramento do modelo de detecção de dano via otimização por classificação. Experimentos mais complexos considerando estruturas de maior dimensão, cenários de múltiplos danos na estrutura, bem como a introdução de ruídos nos dados é crucial para avaliar a robustez do modelo.

7.10 Agradecimentos

Os autores agradecem às instituições de fomento CNPq, CAPES e FAPEMIG pelo contínuo suporte.

7.11 Referências

ALKAYEM, N. F. et al. Structural damage detection using finite element model updating with evolutionary algorithms: a survey. *Neural Computing and Applications*, [S.l.], v. 30, n. 2, p. 389-411, 2017.

ALKAYEM, N. F.; CAO, M. Damage identification single-objective evolutionary algorithms and finite element model updating: evaluation and comparison. **Engineering Optimization**, [S.l.], 2017. DOI: <https://doi.org/10.1080/0305215X.2017.1414206>.

BORGES, C. C. H.; BARBOSA, H. J. C.; LEMONGE, A. C. C. A structural damage identification method based on genetic algorithm and vibrational data. **International Journal for Numerical Methods in Engineering**, [S.l.], v. 69, n. 13, p. 2.663-2.686, 2007.

CURY, A. A.; BORGES, C. C.; BARBOSA, F. S. A two-step technique for damage assessment using numerical and experimental vibration data. **Structural Health Monitoring**, Londres, v. 10, n. 4, p. 417-428, 2010.

DICKSON, J. F. **An exploration and exploitation Pareto approach to surrogate optimization**. 2014. Tese (Doutorado) – The University of Texas at Arlington. Arlington, EUA, 2014.

DOEBLING, S. W. *et al.* Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: a literature review. [S.l.]: LA--13070-MS, 1996.

HASHIMOTO, B. T.; YADLOWSKY, S.; DUCHI, J. C. Derivative free optimization via repeated classification. *arXiv preprint* arXiv:1804.03761, 2018.

HENNIG, P.; SCHULER, C. J. Entropy search for information-efficient global optimization. **Journal of Machine Learning Research**, [S.l.], v. 13, n. 6, 2012.

MIRJALILI, S.; KALAYCI, C. B.; BISWAS, A. A brief tutorial on optimization problems, optimization algorithms, meta-heuristics, and swarm intelligence. In: BISWAS, A.; KALAYCI, C. B.; MIRJALILI, S. (Eds.). **Advances in Swarm Intelligence**. Cham: Springer, 2023. (Studies in Computational Intelligence, v. 1.054).

NEZAMI, N.; ANAHIDEH, H. An empirical review of model-based adaptive sampling for global optimization of expensive black-box functions. arXiv preprint arXiv:2204.10795, Singapore 2022.

REGIS, R. G.; SHOEMAKER, C. A. A stochastic radial basis function method for the global optimization of expensive functions. **INFORMS Journal on Computing**, Catonsville, Maryland, v. 19, n. 4, p. 497-509, 2007.

YU, Y.; QIAN, H.; HU, Y.-Q. Derivative-free optimization via classification. In: **Proceedings of the AAAI Conference on Artificial Intelligence**, Washington, DC, USA, n. 1, 2016.

ZIENKIEWICZ, O. C.; TAYLOR, R. L. **The finite element method**. Butterworth-Heinemann, 2000.

7.12 Sobre os(as) autores(as)

Carlos Cristiano Hasenclever Borges é professor da Universidade Federal de Juiz de Fora (UFJF) no Departamento de Ciência da Computação. Graduado em Engenharia Civil pela Universidade Federal de Juiz de Fora com pós-graduação pela Universidade Federal do Rio de Janeiro COPPE/UFRJ. Participa dos programas de pós-graduação em Modelagem Computacional e Ciência da Computação da UFJF. Suas principais atuações são em Engenharia Estrutural e Sistemas Biológicos nas linhas de Aprendizagem de Máquina e Inteligência Computacional.

Yan Messias de Azevedo Fonseca é graduando em Ciências Exatas e Ciência da Computação pela Universidade Federal de Juiz de Fora (UFJF). Possui experiência em inteligência computacional aplicada à análise de danos estruturais, com interesse em métodos numéricos, otimização e aprendizado de máquina.

8 AUTOCODIFICADORES E SUAS DIFERENTES APLICAÇÕES NA ENGENHARIA

Luiz Tadeu Dias Júnior¹, Marcos Spínola Neto², Mariana Passamai Alvarenga², Renato da Silva Melo¹, Rafaelle Piazzaroli Finotti¹, Flávio de Souza Barbosa¹, Alexandre Abrahão Cury¹

¹ Programa de Pós-graduação em Engenharia Civil, Universidade Federal de Juiz de Fora.

² Faculdade de Engenharia, Universidade Federal de Juiz de Fora.

8.1 Resumo

O monitoramento da integridade estrutural (SHM, do inglês *Structural Health Monitoring*), tem como objetivo garantir a segurança e o funcionamento das estruturas. Nos últimos anos, diversas técnicas baseadas em aprendizado de máquina têm sido utilizadas para esse fim. Dentre elas, destacam-se os autocodificadores (AE, do inglês *Autoencoder*), que são modelos capazes de extrair características a partir de dados de vibração, reduzindo a sua dimensionalidade, constituindo-se como ferramentas eficazes para aplicações de SHM. Nesse contexto, o presente capítulo aborda as características dos autocodificadores e sua aplicabilidade no que tange à detecção de danos. Ademais, utilizando esta metodologia, três exemplos de aplicações são apresentados com base nos sinais vibracionais brutos de uma estrutura apertada ensaiada em laboratório, das pás de uma maquete de turbina eólica e de um modelo numérico de rodas de vagões ferroviários. Para tais dados, diferentes variações dos AEs foram testadas, como o AE Esperso ou SAE (do inglês *Sparse Autoencoder*); AE Variacional ou VAE (do inglês *Variational Autoencoder*) e AE Convolucional ou CAE (do inglês *Convolution Autoencoder*). Os resultados obtidos em cada um desses modelos foram considerados satisfatórios.

Palavras-Chave: Monitoramento da Integridade Estrutural; Autocodificadores; Detecção de dano; Análise vibracional.

8.2 Introdução

Dentre as principais preocupações dos engenheiros ao longo do ciclo de vida das construções, destacam-se o bom funcionamento dos sistemas estruturais e a segurança dos usuários. Considerando-se que as inspeções humanas, quando conduzidas visualmente, podem ser suscetíveis a imprecisões e erros, o monitoramento de integridade estrutural (SHM, do inglês *Structural Health Monitoring*) tem surgido como uma abordagem potencial para a identificação precoce de falhas em estruturas (Sousa; Courage, 2021). Esta metodologia depende principalmente do uso de acelerômetros conectados às estruturas para registrar dados de vibração ao longo do tempo. Com avanços significativos em aprendizado de máquina (ML, do inglês *Machine Learning*) e Inteligência Artificial (IA), esses dados se tornaram não apenas mais precisos, mas também mais acessíveis, possibilitando sua aplicação generalizada (Boratto et al., 2025). Como resultado, sistemas de SHM oferecem uma abordagem mais confiável e econômica para a manutenção estrutural, permitindo a detecção remota de sinais de deterioração com base em limiares predefinidos, o que pode reduzir significativamente os custos de reparo (Finotti, 2022; Cardoso; Cury; Barbosa, 2019; Cury et al., 2022; Carrión et al., 2017).

Nesse sentido, muitas técnicas foram desenvolvidas para detectar, localizar e quantificar os danos estruturais na tentativa de tornar o processo de monitoramento mais viável (Chesné; Deraemaeker, 2013; Amezquita-Sanchez; Adeli, 2016; Meruane; Heylen, 2011). De um modo inicial, para essa tarefa, artigos datados das décadas de 1980 e 1990, se basearam na variação dos parâmetros modais. Nesse contexto, dado que o dano altera as propriedades físicas da estrutura, como sua massa e a sua rigidez, logo poderá alterar também seus parâmetros modais, como a frequência natural, taxas de amortecimento e modos de vibração (Nunes et al., 2021; Shang et al., 2021).

Nos primeiros estudos, a detecção de dano era baseada na avaliação direta das propriedades modais. As frequências naturais, por serem indicadores sensíveis ao estado de integridade de uma estrutura, tendem a apresentar valores ligeiramente menores em situações em que a estrutura se encontra danificada. Cawley e Adams (1979) foram os pioneiros na avaliação da integridade estrutural utilizando como base a variação das frequências naturais como indicador de dano. A partir de então, novos trabalhos foram realizados com o mesmo princípio, Fox (1992) também utilizou a variação da frequência natural para detecção de anomalias para verificar fissuras em uma viga.

Assim, a exploração de outros parâmetros para a detecção de danos gradualmente se tornou o foco central das pesquisas. O MAC (*Modal Assurance Criterion*), proposto por Allemang (1982), mede a correlação entre modos danificados

e não danificados utilizando as variações das amplitudes dos modos de vibração, alternando de 0 (sem correlação) a 1 (correlação perfeita). De maneira similar, Lieven e Ewins desenvolveram o COMAC (*Coordinate Modal Assurance Criterion*), que avalia essa correlação para cada grau de liberdade do sistema estrutural. Com isso, diversas abordagens foram propostas para aumentar a capacidade dos indicadores baseados nos modos próprios para detecção de danos. Em 1991, Pandey, Biswas e Samman apresentaram um indicador baseado na variação da curvatura dos modos naturais de estruturas saudáveis e danificadas, associando a mudança na rigidez de flexão à mudança na curvatura. Dois anos depois, Kim e Stubbs apresentaram um método baseado na variação de energia de deformação, indicando ser possível detectar e localizar a região afetada. Desse modo outros estudos foram surgindo variando outros parâmetros modais, como a matriz de flexibilidade (Pandey; Biswas, 1994) e a variação da energia de deformação (Alvandi; Cremona, 2006). Há pesquisas ainda que uniram dois ou mais parâmetros modais para localizar e quantificar o dano (Cury; Borges; Barbosa, 2011; Doebling et al., 1996).

Ainda que as análises das mudanças de parâmetros modais sejam abordagens capazes de detectar e quantificar o dano em uma estrutura, a obtenção dessas propriedades pode ser afetada por diversos fatores, tanto ambientais (temperatura, vento e radiação solar), quanto operacionais (carregamentos de utilização), prejudicando o uso dessas metodologias em casos práticos de SHM vibração (Nunes et al., 2021; Shang et al., 2021). Nesse contexto, métodos baseados em inteligência artificial emergiram como uma abordagem promissora nas pesquisas.

Com os avanços computacionais, métodos que utilizam diretamente dados vibracionais brutos estão se tornando mais dominantes (Carrión et al., 2017; Alves, 2012; Alves; Cury, 2023). Essas abordagens podem detectar alterações estruturais processando sinais adquiridos da estrutura ao longo do tempo, extraíndo características relevantes e realizando classificações com custos computacionais relativamente baixos. Um autocodificador (AE, do inglês *Autoencoder*), é um modelo de aprendizado não supervisionado (Amaral et al., 2016; Finotti et al., 2022; Boratto et al., 2025) projetado para reconstruir dados de entrada e reduzir a dimensionalidade. Ele comprime informações em uma representação latente e reconstrói os dados originais a partir desta forma reduzida. Composto por um codificador e um decodificador, ele minimiza a diferença entre a entrada e a saída reconstruída. Existem variações específicas, como autocodificadores esparsos (SAEs, do inglês *Sparse Autoencoder*), que introduzem restrições de regularização para forçar a rede a aprender representações mais eficientes (Finotti et al., 2021; Finotti, 2022; Finotti et al., 2022); autocodificadores variacionais (VAEs, do inglês *Variational Autoencoder*), que incorporam uma abordagem probabilística para modelar a distribuição dos dados (Dias, 2024); e autocodificadores convolucionais (CAEs, do inglês *Convolutional*

Autoencoder), que são adaptados para processar dados de imagem capturando características espaciais (Dalcin, 2024; Resende et al., 2024; Spínola Neto et al., 2024).

8.3 Metodologia

A metodologia proposta visa avaliar a capacidade dos AE de separar, de maneira não supervisionada, sinais de vibração pertencentes a diferentes comportamentos dinâmicos estruturais. Isso é alcançado treinando-se o modelo com apenas uma parte dos dados estruturais íntegros e, posteriormente, testando-o com os dados restantes. Durante esse processo, o modelo compara cada sinal à classe de referência e calcula o erro de reconstrução.

Primeiramente, as bases de dados contendo os sinais dinâmicos brutos no domínio do tempo foram separadas/coletadas. Para as estruturas dos itens 8.4.1 e 8.4.2, a Transformada Rápida de Fourier (FFT, do inglês *Fast Fourier Transform*) foi usada nos sinais estruturais. Essa abordagem realiza a transformação dos sinais no domínio do tempo para o da frequência. Essa escolha foi motivada pelo fato de que as compressões e reconstruções realizadas pelos AE foram mais precisas nesse domínio em comparação ao domínio temporal (Resende et al., 2022), assim os dados de entrada para o autocodificador ficaram no domínio da frequência. Já para as rodas férreas exemplificadas no item 8.4.3, os sinais dinâmicos no tempo não sofreram alterações.

Após realizar ou não a FFT sobre os dados dinâmicos brutos, todos os resultados foram padronizados usando a normalização *z-score*. Esse procedimento transforma os dados originais em uma escala comum com média zero e desvio-padrão unitário, e é aplicado antes que os AEs processem os dados. A equação 1 descreve matematicamente essa transformação:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

Onde z representa o vetor padronizado, x o vetor original, μ a média dos dados e σ o desvio-padrão.

Após a normalização, todos os dados são divididos em três conjuntos da seguinte forma:

- **Fase de Treinamento:** nesta etapa, um conjunto de dados extraídos do estado não danificado da estrutura é usado para treinar o modelo de autocodificador. Este conjunto de dados é chamado de conjunto de treinamento.
- **Fase de Validação:** durante esta fase, outro conjunto de dados (de validação), também extraído do mesmo estado estrutural da fase de treinamento,

é aplicado ao modelo treinado na fase anterior. O objetivo é verificar a capacidade de classificar novos dados. Espera-se que o modelo resulte em valores T^2 estatisticamente similares para os conjuntos de treinamento e validação, uma vez que pertencem ao mesmo estado estrutural.

- **Fase de Monitoramento:** nesta fase, conjuntos de dados (de monitoramento) extraídos de outros casos estruturais — diferentes dos utilizados nas fases de treinamento e validação — são apresentados ao modelo. Espera-se que o modelo produza valores T^2 mais altos do que os obtidos nas fases anteriores, já que pertencem a um estado estrutural diferente daquele usado para treinamento.

Todos os dados das fases de treinamento e validação das aplicações são compostos pelo cenário em que a estrutura se encontra sem danos. Durante o treinamento, os diferentes tipos de autocodificadores utilizados (AE, SAE, VAE e CAE, a depender da estrutura) foram otimizados utilizando o *Optuna* (Akiba et al., 2019), treinando o modelo com parte dos dados da estrutura sã e utilizando o restante para validação.

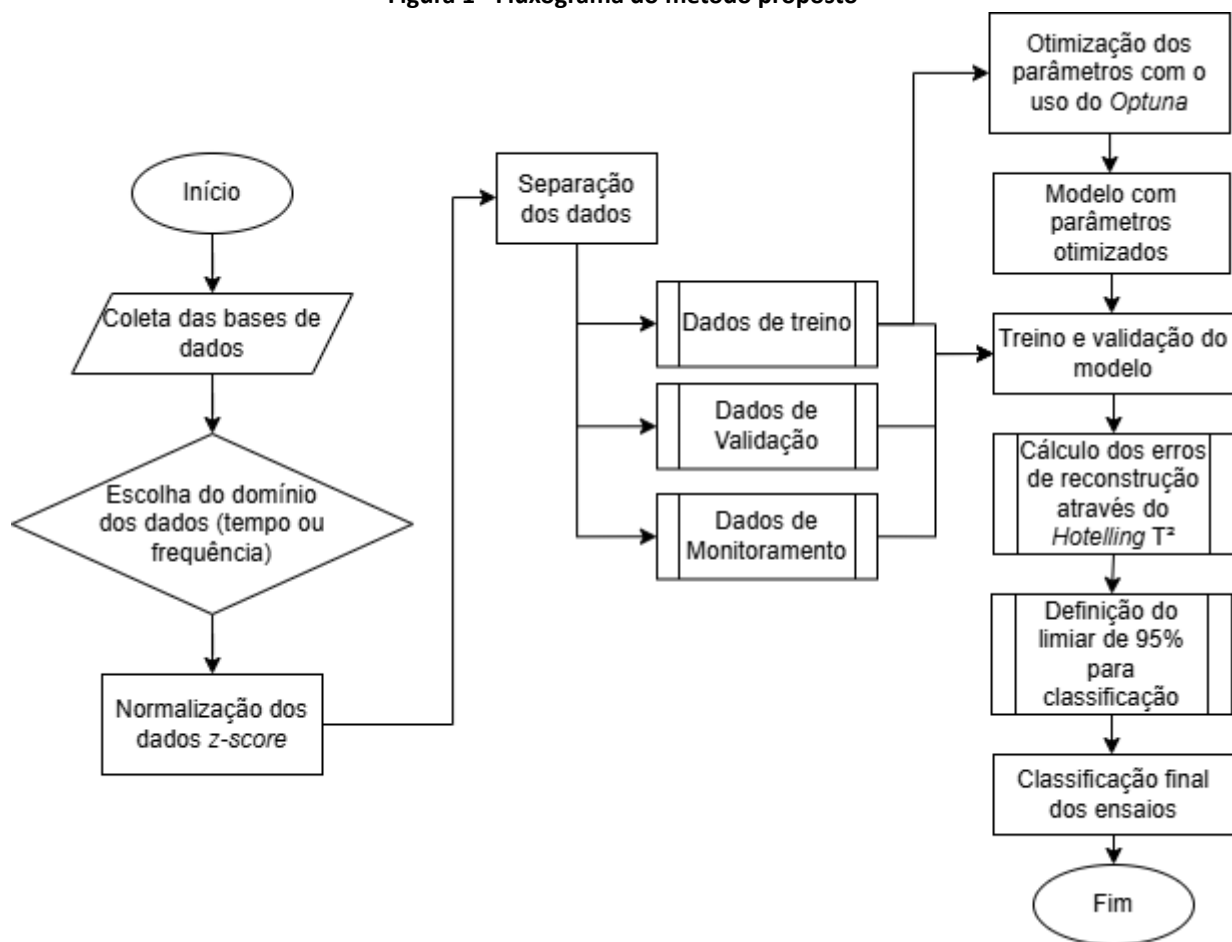
Com este elemento otimizado, os sinais dos demais cenários foram reconstruídos para realizar o cálculo da estatística *Hotelling* T^2 (Montgomery, 2007). O T^2 é uma ferramenta gráfica estatística usada para avaliar a influência de vários parâmetros de um problema ao longo do tempo. Ela exibe vários pontos de dados, compostos de uma característica estatística específica, com linhas horizontais separando diferentes classes de cenários estruturais. Pontos fora dos intervalos esperados indicam mudanças, sugerindo uma situação fora de controle (Montgomery, 2007). Assim, dada uma matriz $H_{N \times M}$ representando um conjunto de dados ao longo de um determinado período, o T^2 pode ser escrito através da equação 2:

$$T^2 = R(\underline{h} - \bar{h})^T S^{-1}(\underline{h} - \bar{h}) \quad (2)$$

onde \underline{h} é o vetor médio da amostra de M características disponíveis, obtido de uma submatriz H com R observações ($H_{R \times M}$, $R < N$); \bar{h} e S^{-1} são o vetor médio de referência e a média das matrizes de covariância de referência, respectivamente.

O esperado é um aumento gradual dos valores de T^2 na medida em que se aumenta o dano, permanecendo relativamente constante dentro de cada classe. Por fim, o último passo é a classificação dos dados. Para essa etapa, foi usado um limiar pré-fixado (UCL, do inglês *Upper Control Limit*) acima dos 95% desses valores obtidos durante a fase de treinamento para separar os dados com e sem anomalia. A Figura 1 mostra um resumo de como funciona a metodologia proposta.

Figura 1 - Fluxograma do método proposto



Fonte: Autores.

8.4 Aplicações e resultados

8.4.1 Pórtico tridimensional – “Yellow Frame”

O “Yellow Frame” (Figura 2) é um pórtico de quatro pavimentos instalado sobre uma laje de concreto localizada externamente ao Laboratório de Pesquisa em Engenharia Sísmica da UBC (Mou et al., 2015). A estrutura tem uma altura de 3,6 m e uma planta de 2,5 m × 2,5 m, e seus membros são feitos de aço laminado à quente, com uma tensão de escoamento nominal de 300 MPa. Por pavimento, esse pórtico possui 9 colunas tipo B100 e 11 vigas tipo S75.

Essa estrutura foi projetada para simular diferentes condições ambientais, sendo avaliados seis cenários de danos (Tabela 1), obtidos pela remoção ou inserção gradual de contraventamentos. Durante todos os testes, havia quinze acelerômetros operando com frequência de amostragem de 200 Hz. Além disso, foi aplicado um filtro *anti-aliasing* com frequência de corte ajustada para 50 Hz.

Figura 2 - “Yellow Frame” (a) sem contraventamentos e (b) com contraventamentos



Fonte: Mou et al. (2015).

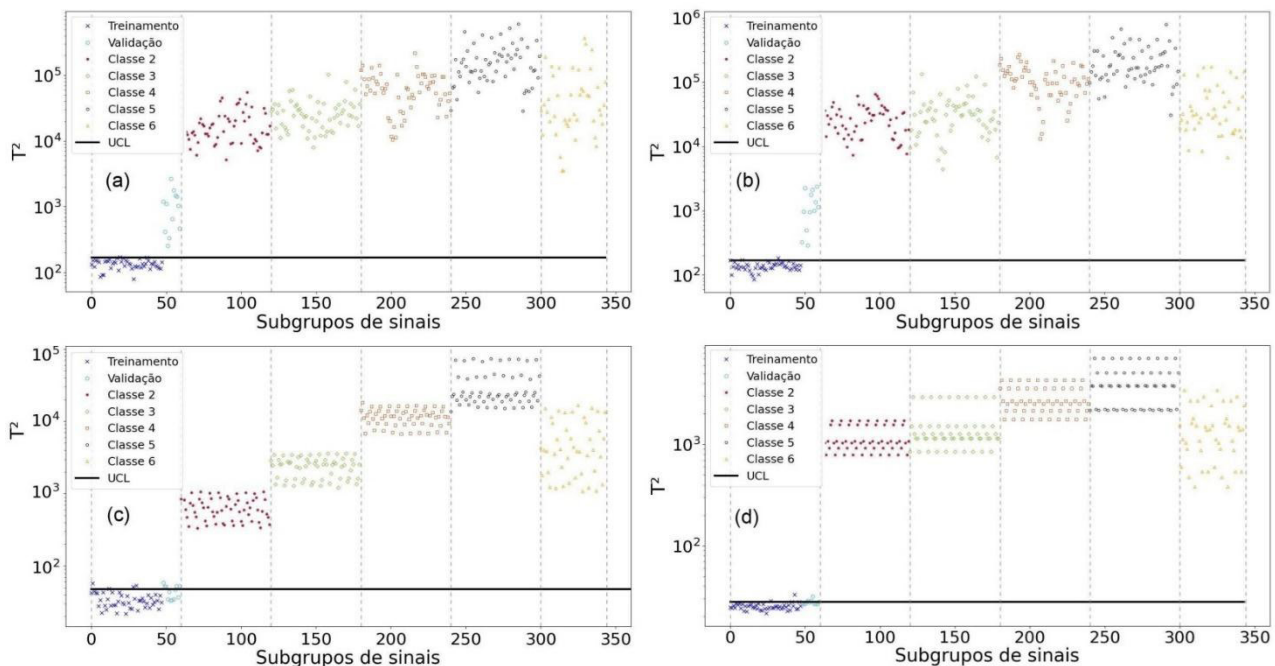
Tabela 1 – Cenários estruturais nas análises do pórtico tridimensional

Cenário	Configuração
1	Estrutura completamente contraventada;
2	Remoção dos contraventamentos do 1º pavimento de uma baía no canto sudeste;
3	Remoção dos contraventamentos dos 1º e 4º pavimentos de uma baía no canto sudeste;
4	Remoção dos contraventamentos de todos os pavimentos de uma baía no canto sudeste;
5	Remoção dos contraventamentos do 2º pavimento na face norte;
6	Remoção de todos os contraventamentos do lado leste;

Fonte: Autores.

Os cenários de 1 a 5 estão organizados conforme a progressão dos danos, enquanto o cenário 6 simula um reparo na estrutura. Nesta estrutura, todas as metodologias analisadas obtiveram valores de T^2 similares entre as classes de validação e treinamento nos acelerômetros, confirmando a capacidade dos modelos de classificar novos dados, já que os de validação e treinamento pertencem ao mesmo estado estrutural. A Figura 3 apresenta os resultados para os diferentes tipos de autocodificadores testados para o acelerômetro 4 (todos os demais obtiveram resultados semelhantes).

Figura 3 - Resultados do pórtico tridimensional para a remoção de contraventamento para o acelerômetro 4 utilizando como autocodificador o (a) AE; (b) SAE; (c) VAE; (d) CAE



Fonte: Autores.

Analisando os resultados da Figura 3, é possível afirmar que todos os métodos identificaram corretamente a presença de alterações estruturais, pois todas as classes de monitoramento excederam o UCL. Entretanto, é visível que o AE e o SAE (Figuras 3a,b) não foram capazes de identificar os dados de validação como sendo da mesma classe dos de treinamento. Em contrapartida, o VAE e o CAE forneceram bons resultados para a identificação das alterações estruturais, pois não só classificaram corretamente os sinais de validação como semelhantes aos de treinamento, como também todas as classes de monitoramento ficaram acima da UCL.

Além disso, os dados pertencentes à Classe 6 ficaram com valores de T^2 predominantemente inferiores aos da Classe 5, identificando a inserção de contraventamentos, simulando um reparo estrutural. Entre todas as metodologias avaliadas, o VAE (Figura 3c) se destacou novamente como o mais eficaz na quantificação das alterações, pelo aumento nos valores de T^2 na medida em que a remoção dos contraventamentos foi realizada.


8.4.2 Turbina eólica

Para a realização desse estudo de detecção de alterações estruturais, utilizou-se uma maquete de turbina eólica, simulando as características gerais de uma turbina de baixa capacidade. A turbina é composta por uma torre de aço de 3 metros de altura e três pás (A, B e C), cada uma com 2,4 metros de comprimento e pesando 12 kg. O sistema de rotação inclui um motor de 1 HP acoplado a uma caixa de

engrenagens com redução de 1:10 e um eixo de transmissão que faz o cubo girar. As pás estão conectadas ao mecanismo de rotação através de um cubo hexagonal de aço, que permite ajustes manuais de ângulos de inclinação em posições fixas de 36°. A velocidade de rotação é controlada por um inversor de frequência, com uma faixa de velocidade de 0 a 60 RPM. O sistema de aquisição de dados instalado no cubo de aço inclui sensores de temperatura AM2302/DS18B20 e sensores de aceleração ADXL345. Este sistema registra dados a uma frequência de amostragem de 200 Hz durante 10 minutos, seguido por um período de transmissão de dados de igual duração, totalizando um ciclo de medição de 20 minutos.

Para simular os diferentes cenários de danos (Tabela 2), foram criadas fissuras na pá A e comparados os sinais de vibração da pá A intacta com os sinais após a introdução das fissuras. Cada pá foi equipada com uma tira de três sensores de aceleração. Na Figura 4 são apresentadas as localizações das fissuras e dos sensores de aceleração nas pás (S1, S2 e S3). Cada sensor mediu as acelerações em duas direções: x (na borda) e z (perpendicular ao plano de rotação da pá).

Figura 4 - Distribuição dos sensores de aceleração (S1, S2, S3) e localizações das fissuras na pá A da turbina



Fonte: Autores.

Tabela 2 – Cenários estruturais nas análises da turbina eólica

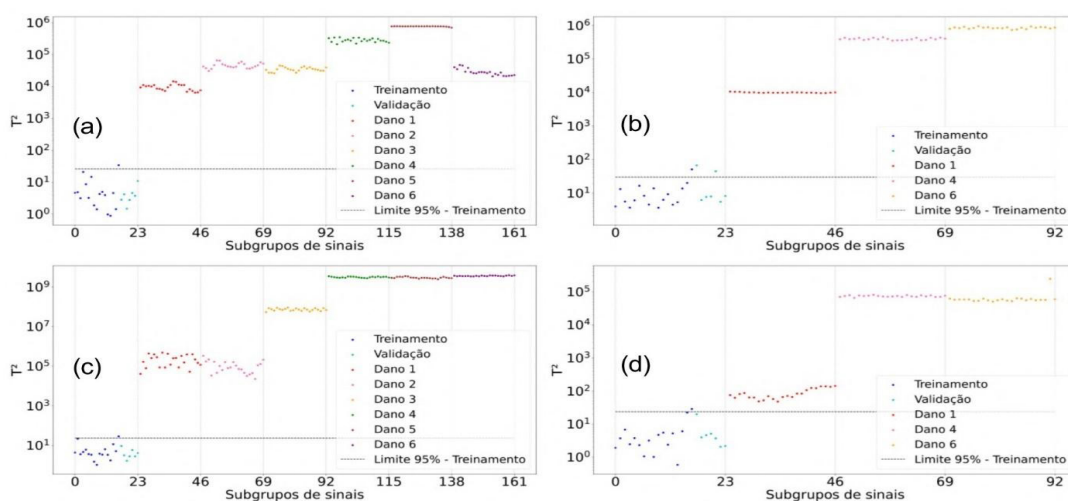
Cenário	Configuração
0	Estado saudável
1	Fissura 1 = 2 cm;
2	Fissura 1 = 5 cm;
3	Fissura 1 = 5 cm, Fissura 2 = 2 cm, Fissura 3 = 2 cm;
4	Fissura 1 = 5 cm, Fissura 2 = 5 cm, Fissura 3 = 5 cm;
5	Fissura 1 = 10 cm, Fissura 2 = 8 cm, Fissura 3 = 5 cm;
6	Fissura 1 = 10 cm, Fissura 2 = 8 cm, Fissura 3 = 10 cm

Fonte: Autores.

As Figuras 5 e 6 apresentam os resultados do cálculo utilizando o *Hotelling* T^2 para os dados extraídos da reconstrução realizada pelo autocodificador esparsos

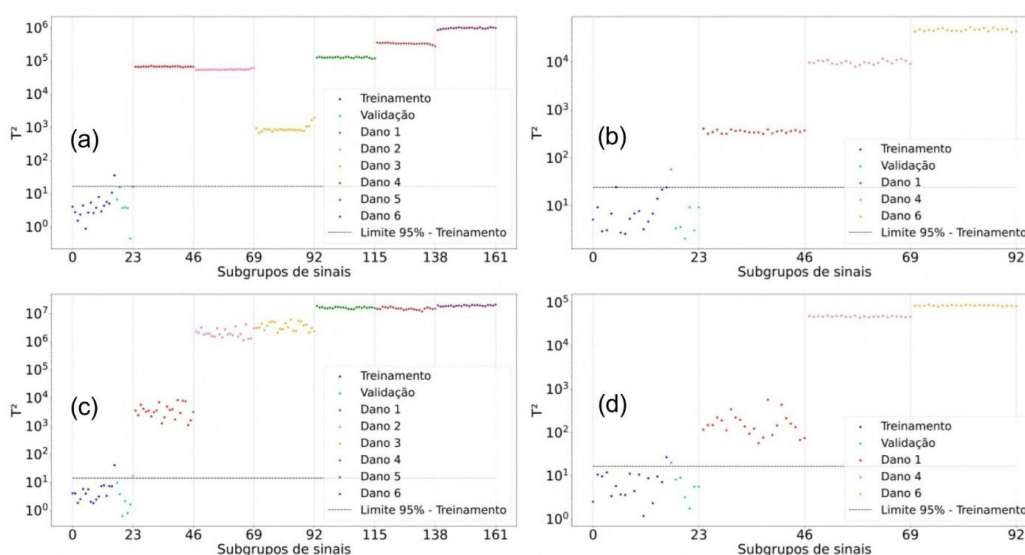
(SAE) para as direções X e Z, respectivamente. Analogamente ao item anterior, o modelo também foi capaz de detectar fissuras e manteve a proximidade dos valores de T^2 entre os dados de treinamento e os dados de validação. Porém, observa-se uma diferença nos valores de T^2 entre as classes de dano, como evidenciado na Figura 5c. Esses resultados indicam que o modelo não só foi eficaz na identificação da presença das fissuras, como também conseguiu quantificar a gravidade dos danos com precisão significativa.

Figura 5 - Resultados da análise de fissura para a direção X. (a) 15 RPM; (b) 30 RPM; (c) 45 RPM; (d) 60 RPM



Fonte: Autores.

Figura 6 - Resultados da análise de fissura para a direção Z. (a) 15 RPM; (b) 30 RPM; (c) 45 RPM; (d) 60 RPM



Fonte: Autores.

8.4.3 Rodas ferroviárias


Os dados utilizados para este caso, foram obtidos por meio de simulações numéricas que reproduzem as respostas dinâmicas obtidas por sistemas de medição de beira de pista durante a movimentação de veículos ferroviários com distintos estágios de poligonização das rodas, disponíveis em Alvarenga et al. (2024). Esses dados representam um subconjunto das simulações originalmente desenvolvidas e utilizadas por Magalhães et al. (2024) que, na ocasião, aplicaram estratégias SHM usando autocodificadores esparsos para a identificação de distintas tipologias de danos em rodas ferroviárias, sendo neste caso avaliadas as presenças de rodas íntegras, planas e poligonais. As simulações da interação dinâmica entre o veículo e a via foram realizadas utilizando um *software* interno denominado *Vehicle-Structure Interaction Analysis* (VSI), desenvolvido na linguagem do software *MATLAB*[®] e implementado nos estudos dos autores Magalhães et al. (2024).

A análise realizada pelo VSI considera um modelo tridimensional de contato roda-trilho que integra o veículo e a via através da teoria Hertziana (Hertz, 1882, p. 156). O *software* também utiliza uma rotina denominada USETAB de Kalker (Kalker, 1996), que considera o cálculo de contato via-veículo totalmente não linear, de modo a representar a complexidade do problema de maneira mais fidedigna possível, considerando inclusive o cálculo das forças normais e tangenciais resultantes da fluência por atrito do rolamento. Embora os modelos de subsistemas tenham sido inicialmente desenvolvidos de formas independentes, o VSI os integra por meio de uma abordagem de acoplamento abrangente (Magalhães et al., 2024). A abordagem em relação a interação veículo-via adotada no VSI é detalhadamente descrita nos estudos de Montenegro et al., (2015; 2024) e tem sido aplicada de maneira recorrente em outros estudos, como Guedes et al. (2023), Silva et al. (2023) e Mosleh et al. (2022).

Os dados obtidos através do VSI, utilizando a metodologia descrita anteriormente foram utilizados neste estudo com o propósito de detectar distintos estágios de poligonização em rodas ferroviárias. Tais imperfeições são caracterizadas por irregularidades periódicas na banda de rodagem radial da roda ao longo de sua circunferência, sobrepondo-se a um raio constante da roda (Nielsen e Johansson, 2000).

Nesta aplicação, os registros de aceleração vertical simulados foram realizados por seis acelerômetros dispostos em distintas posições do trilho a meio-vão entre dormentes considerando os lados direito e esquerdo dos trilhos (Figura 7). A frequência de amostragem dos dados é de 10 kHz e foi inserido um ruído artificial nos dados igual a 5%. Além disso, foram considerados dois estágios de poligonização das rodas e um terceiro cenário no qual as rodas apresentavam-se íntegras, sem a ocorrência de danos. O autocodificador variacional (VAE) foi usado nessa abordagem.

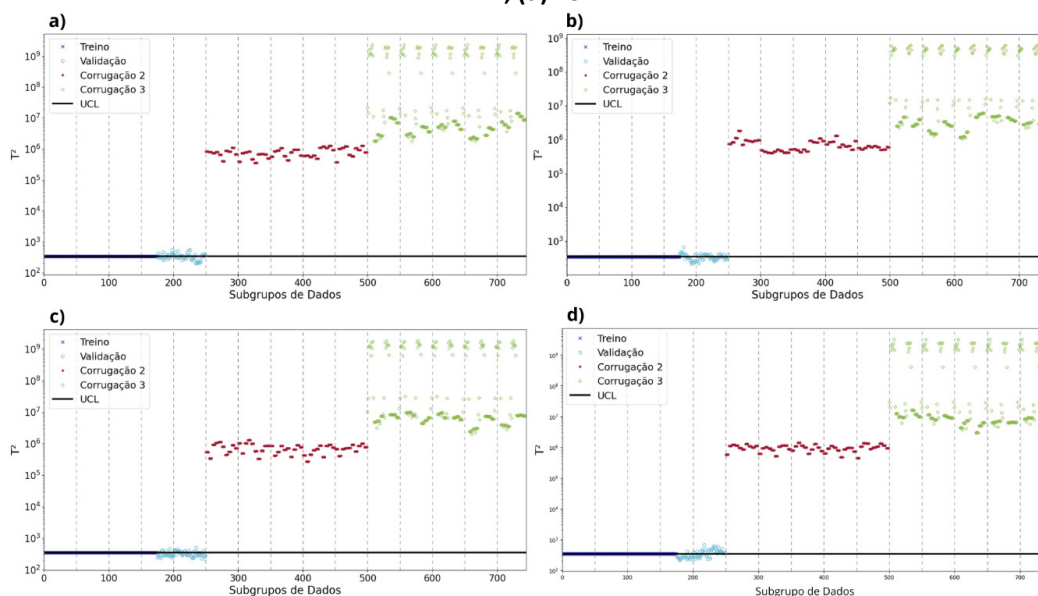
Figura 7 - Sistema de monitoramento virtual de beira de estrada indicando os locais dos acelerômetros: (a) vista traseira; (b) vista superior



Fonte: Adaptado de Magalhães et al. (2024).

Em todas as situações avaliadas, observou-se que a maior parte dos valores de T^2 dos dados de treinamento e validação permaneceram abaixo da UCL, indicando um bom comportamento do modelo na classificação de novos dados. Como os conjuntos de treinamento e validação pertencem a mesma classe de dano, era esperado que os valores de T^2 fossem semelhantes, o que de fato se confirma. Além disso, os hiperparâmetros selecionados em todas as análises permitiram a correta identificação de alteração estrutural nas rodas e uma correta classificação dos danos, uma vez que todos os níveis monitorados excederam a UCL, e foram classificados de acordo com a gravidade do estágio de poligonização das rodas, conforme ilustrado na Figura 8.

Figura 8 - Hotelling T^2 para os estágios de poligonização das rodas, a partir de sinais dinâmicos coletados pelo acelerômetro 1 posicionado a meio vão entre dormentes nas repetições do ensaio. (a) 1; (b) 6; (c) 11; (d) 16



Fonte: Autores.

8.5 Considerações Finais

Este estudo investigou eficácia de diferentes variações de autocodificadores – tradicional (AE), esparsos (SAE), variacional (VAE) e convolucional (CAE) – combinados com a ferramenta estatística *Hotelling T²*, na detecção de danos em três diferentes tipos de estruturas. Os resultados demonstraram que, na maioria dos casos, os modelos foram capazes de identificar com precisão os dados pertencentes a um mesmo conjunto de danos, além de identificar a presença de danos na estrutura. Em algumas situações foi possível até quantificar, de forma aproximada, as anomalias detectadas, evidenciando o potencial dos modelos para aplicações práticas.

Além disso, através de uma abordagem não supervisionada, pôde-se perceber que os modelos de AE se comportaram de maneira heterogênea. Conclui-se, portanto, que não existe um modelo universalmente superior, mas sim aquele que melhor se adapta a cada conjunto de dados e cenário analisado, sendo, então, importante selecionar e ajustar os modelos de forma individual para cada estrutura, considerando as particularidades de cada aplicação para maximizar a eficiência na detecção de danos estruturais.

8.6 Agradecimento

Este trabalho foi financiado pela CAPES (Código Financeiro 0001), Conselho Nacional de Desenvolvimento Científico e Tecnológico — CNPq (Brasil) — Projetos CNPq/ FNDCT/ MCTI 407256/2022-9, 402533/2023-2, 303982/2022-5 e 308008/2021-9 e Fundação de Amparo à Pesquisa do Estado de Minas Gerais — FAPEMIG — Processo BPD-00080-22 e APQ-00032-24.

8.7 Referências

AKIBA, T. et al. Optuna: a next generation hyperparameter optimization framework.

In: PROCEEDINGS IN 25th ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY & DATA MINING (KDD '19), p. 2.623-2.631, 2019. DOI: <https://doi.org/10.1145/3292500.3330701>.

ALLEMANG, R. J. A correlation coefficient for modal vector analysis. In: **Proceedings of the 1st IMAC**, Orlando, 1982. p. 110-116, 1982.

ALVANDI, A.; CREMONA, C. Assessment of vibration-based damage identification techniques. **Journal of Sound and Vibration**, Amsterdam, v. 292, n. 1-2, p. 179-202, 2006.

ALVARENGA, M. P. et al. Monitoramento da integridade estrutural de torres eólicas utilizando autocodificadores esparsos. In: XXVII ENCONTRO NACIONAL DE MODELAGEM COMPUTACIONAL, Ilhéus, Anais [...], Bahia, 2024.

ALVES, V. N. **Estudo de novas estratégias para identificação de danos estruturais a partir de dados vibracionais**. 188 f., 2012. Dissertação (Mestrado) — Universidade Federal de Ouro Preto. Ouro Preto, Brasil, 2012.

ALVES, V.; CURY, A. An automated vibration-based structural damage localization strategy using filter-type feature selection. **Mechanical Systems and Signal Processing**, Amsterdam, v. 190, p. 110-145, 2023.

ALVES, V. et al. Novelty detection for SHM using raw acceleration measurements. **Structural Control and Health Monitoring**, Londres, v. 22, n. 9, p. 1.193-1.207, 2015.

AMARAL, R. P. F. et al. Aplicação de métodos computacionais a dados vibracionais para detecção de alterações estruturais. In: XII SIMPÓSIO DE MECÂNICA COMPUTACIONAL, 2016. Uberlândia, Anais eletrônicos. Disponível em: <https://doity.com.br/simmec2016/blog/anais>. Acesso em: 4 ago. 2025.

AMEZQUITA-SANCHEZ, J. P.; ADELI, H. Signal processing techniques for vibration-based health monitoring of smart structures. *Archives of Computational Methods in Engineering*, 2016. DOI: <https://doi.org/10.1007/s11831-014-9135-7>.

BORATTO, T. et al. An agglomerative clustering combined with an unsupervised feature selection approach for structural health monitoring. **Infrastructures**, Basel, v. 10, p. 32, 2025.

CARDOSO, A. C.; CURY, A.; BARBOSA, F. Automated real-time damage detection strategy using raw dynamic measurements. *Engineering Structures*, Amsterdam, v. 196, p. 1-16, 2019. (ISSN 1557-9662).

CARRIÓN, F. J.; QUINTANA, J. A.; CRESPO, S. E. Techno-economical and practical considerations for SHM systems. **Journal of Civil Structural Health Monitoring**, Heidelberg, v. 7, p. 207-215, 2017. DOI: <https://doi.org/10.1007/s13349-017-0215-x>.

CAWLEY, P.; ADAMS, R. D. The location of defects in structures from measurements of natural frequencies. **The Journal of Strain Analysis for Engineering Design**, Londres, v. 14, n. 2, p. 49-57, 1979.

CHESNÉ, S.; DERAEMAEKER, A. Damage localization using transmissibility functions: a critical review. **Mechanical Systems and Signal Processing**, Amsterdam, v. 38, n. 2, p. 569-84, 2013. DOI: <https://doi.org/10.1016/j.ymssp.2013.01.020>.

CURY, A. **Techniques d'anormalité appliqués à la surveillance de santé structurale**. 2010. Tese (Doutorado) — Université Paris-Est, 2010.

CURY, Alexandre et al. (Ed.). **Structural health monitoring based on data science techniques**. Springer, 2022.

DALCIN, M. J. S. **Aplicação de autocodificadores convolucionais para identificação de danos em estruturas**. 176 f., 2024. Dissertação (Mestrado) — Universidade Federal de Juiz de Fora. Juiz de Fora, Brasil, 2024.

DIAS, L. T. J. **Uso de autocodificadores variacionais para a detecção de danos estruturais**. 111 f., 2024. Dissertação (Mestrado) — Universidade Federal de Juiz de Fora. Juiz de Fora, Brasil, 2024.

DOEBLING, S. W. et al. **Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: A literature review**. Los Alamos, EUA: Los Alamos National Lab. (LANL), 1996.

FINOTTI, R. P. **Inteligência artificial aplicada ao monitoramento de estruturas: Detecção de alterações mecânico-estruturais baseada no uso de redes neurais autocodificadoras esparsas para a caracterização de respostas dinâmicas**. 169 f., 2022. Tese (Doutorado) — Universidade Federal de Juiz de Fora. Juiz de Fora, Brasil, 2022.

FINOTTI, R. P. et al. Numerical and experimental evaluation of structural changes using sparse auto-encoders and SVM applied to dynamic responses. **Applied Sciences**, Basel, v. 11, n. 24, p. 11.965, 2021.

FINOTTI, R. P. et al. Structural novelty detection based on sparse autoencoders and control charts. **Structural Engineering and Mechanics**, Seul, v. 81, n. 5, p. 647-664, 2022.

FOX, C. The location of defects in structures- a comparison of the use of natural frequency and mode shape data. In: 10th INTERNATIONAL MODAL ANALYSIS CONFERENCE, Orlando, Anais eletrônicos disponível em: <https://ui.adsabs.harvard.edu/abs/1992imac.conf..522F/abstract>. Acesso em: 4 ago. 2025., Flórida, v. 1, p. 522-528, 1992.

GUEDES, A. et al. Detection of wheel polygonization based on wayside monitoring and artificial intelligence. **Sensors**, Basel, v. 23, n. 4, p. 2.188, 2023. DOI: <https://doi.org/10.3390/s23042188>.

HERTZ, H. Ueber die Berührung fester elastischer Körper. **Journal für die reine und angewandte Mathematik**, Berlim, v. 92, p. 156-171, 1882.

KALKER, J. J. **Book of tables for the Hertzian creep-force law. Mini Conference on Contact Mechanics and Wear of Wheel/Rail Systems**. Budapeste: Budapest University of Technology and Economics, 1996.

KIM, J.; STUBBS, N. **Assessment of the relative impact of model uncertainty on the accuracy of global nondestructive damage detection in structures**. Texas A&M University, Texas, 1993.

LIEVEN, N.; EWINS, D. Spatial correlation of mode shapes, the coordinate modal assurance criterion (COMAC). In: PROCEEDINGS OF THE SIXTH INTERNATIONAL MODAL ANALYSIS CONFERENCE, Kissimmee, Anais eletrônicos disponíveis em: <https://doi.org/10.1115/1.3269816>. Acesso em 04. Ag, Flórida, v. 1, p. 690-695, 1988.

MAGALHAES, J. et al. A strategy for out-of-roundness damage wheels identification in railway vehicles based on sparse autoencoders. **Railway Engineering Science**, 2024. DOI: <https://doi.org/10.1007/s40534-024-00338-4>.

MERUANE, V.; HEYLEN, W. An hybrid real genetic algorithm to detect structural damage using modal properties. **Mechanical Systems and Signal Processing**, Amsterdam, v. 25, n. 5, p. 1.559-1.573, 2011. DOI: <https://doi.org/10.1016/j.ymsp.2010.11.020>.

MONTENEGRO, P. A.; CALÇADA, R. Wheel–rail contact model for railway vehicle–structure interaction applications: development and validation. **Railway Engineering Science**, Heidelberg, v. 31, n. 3, p. 181-206, 2024. DOI: <https://doi.org/10.1007/s40534-023-00306-4>.

MONTENEGRO, P. A.; VIEIRA, R. C.; PEREIRA, A. P. Wheel–rail contact formulation for analyzing the lateral train–structure dynamic interaction. **Computers & Structures**, Amsterdam, v. 152, p. 200-214, 2015. DOI: <https://doi.org/10.1016/j.compstruc.2015.01.004>.

MONTGOMERY, D. **Introduction to Statistical Quality Control**. Hoboken, USA: John Wiley & Sons, 2007.

MOSLEH, A. et al. Early wheel flat detection: an automatic data-driven wavelet-based approach for railways. **Vehicle System Dynamics**, Philadelphia, v. 61, n. 6, p. 1.644-1.673, 2022. DOI: <https://doi.org/10.1080/00423114.2022.2103436>.

MOU, M. et al. **Database for Structural Control and Monitoring Benchmark Problems**. 2015. Disponível em: <https://datacenterhub.org/resources/257>. Acesso em: 22 nov. 2024.

NIELSEN, J. C. O.; JOHANSSON, A. Out-of-round railway wheels — A literature survey. Proceedings of the Institution of Mechanical Engineers, Part F, Journal of Rail and Rapid Transit, Londres, v. 214, p. 79-91, 2000. DOI: <https://doi.org/10.1243/0954409001531351>.

NUNES, L. A. et al. A hybrid learning strategy for structural damage detection. **Structural Health Monitoring**, Londres, v. 20, n. 4, p. 2.143-2.160, 2021.

PANDEY, A.; BISWAS, M.; SAMMAN, M. Damage detection from changes in curvature mode shapes. **Journal of Sound and Vibration**, Amsterdam, v. 145, n. 2, p. 321-332, 1991.

PANDEY, A.; BISWAS, M. Damage detection in structures using changes in flexibility. **Journal of Sound and Vibration**, Amsterdam, v. 169, n. 1, p. 3-17, 1994.

RESENDE, L. et al. Structural damage detection with autoencoding neural networks. In: XLIII IBERO-LATIN AMERICAN CONGRESS ON COMPUTATIONAL METHODS IN ENGINEERING. Foz do Iguaçu, Brasil, 2022. DOI: <https://doi.org/10.1177/14759217231193102>.

RESENDE, L. et al. Damage identification using convolutional neural networks from instantaneous displacement measurements via image processing. **Structural Health Monitoring**, Londres, v. 23, p. 1.627-1.640, 2024.

SHANG, Z. et al. Vibration-based damage detection for bridges by deep convolutional denoising autoencoder. **Structural Health Monitoring**, Londres, v. 20, n. 4, p. 1.880-1.903, 2021.

SILVA, R. et al. Identification of unbalanced freight traffic loads based on wayside monitoring and artificial intelligence. **Sensors**, Basel, v. 23, p. 1.544, 2023. DOI: <https://doi.org/10.3390/s23031544>.

SOUSA, H.; COURAGE, W. Value of information of a pro-active SHM-based tool supported by advanced FE models and Bayesian statistics towards efficiency in bridge management. **Structural Infrastructure Engineering**, Abingdon, v. 18, p. 554-572, 2021. DOI: <https://doi.org/10.1080/15732479.2021.1978507>.

SPÍNOLA NETO, M. et al. Structural damage identification using autoencoders: a comparative study. **Buildings**, Basel, v. 14, n. 7, p. 2.014, 2024. DOI: <https://doi.org/10.3390/buildings14072014>.

8.8 Sobre os(as) autores(as)

Luiz Tadeu Dias Júnior é doutorando na Universidade Federal de Juiz de Fora (UFJF), no programa de pós-graduação em Engenharia Civil. Faz parte do CIDENG-CNPq — Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia. Tem experiência na área de aprendizagem de máquina aplicada à detecção de dano em estruturas civis.

Marcos Spínola Neto é estudante de Engenharia Civil pela Universidade Federal de Juiz de Fora (UFJF). Realiza pesquisa sobre o uso de autocodificadores na detecção de danos estruturais, aplicando aprendizado de máquina em análises dinâmicas de estruturas civis.

Mariana Passamai Alvarenga é estudante de Engenharia Civil pela Universidade Federal de Juiz de Fora (UFJF). Realiza pesquisa sobre o uso de autocodificadores na detecção de danos estruturais, aplicando aprendizado de máquina em análises dinâmicas de estruturas civis.

Renato da Silva Melo é mestrando no programa de pós-graduação em Engenharia Civil pela Universidade Federal de Juiz de Fora. Integra o CIDENG-CNPq — Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia, onde desenvolve pesquisas relacionadas a aprendizado profundo com foco em detecção de danos em estruturas ferroviárias.

Rafaelle Piazzaroli Finotti é mestra e doutora em Modelagem Computacional pela Universidade Federal de Juiz de Fora (2017 e 2022, respectivamente). Graduada em Engenharia Civil pela mesma instituição de ensino (2014). Tem experiência na área de Engenharia Civil com ênfase em Inteligência Artificial, mais especificamente em Aprendizado de Máquinas, aplicada à Mecânica das Estruturas, atuando principalmente nos seguintes temas: Monitoramento da Integridade Estrutural, Detecção de Dano, Dinâmica das Estruturas, Análise Estatística e Mineração de Dados.

Flávio de Souza Barbosa é Professor Titular da UFJF, membro permanente do Programa de Pós-Graduação em Engenharia Civil e colaborador do Programa de Pós-Graduação em Modelagem Computacional. Foi coordenador do PPG em Engenharia Civil da UFJF (2019-2023). Suas áreas de atuação incluem Modelagem Computacional, Monitoramento Estrutural e de Ferrovias (SHM), Inteligência Artificial e Processamento de Imagens aplicados a SHM. Graduado em Engenharia Civil pela UFJF (1994), com Mestrado (1996) e Doutorado (2000) em Engenharia Civil pela COPPE/UFRJ. Realizou Pós-Doutorado no LCPC (França). Editor da revista *Structural Engineering International* desde 2015 e membro de diversas associações científicas.

Alexandre Abrahão Cury é Professor Associado da UFJF, graduado em Engenharia Civil pela UFJF, mestre em Modelagem Computacional pela mesma instituição e doutor em Engenharia Civil pela École Nationale des Ponts et Chaussées. Suas pesquisas abordam monitoramento de integridade estrutural, *machine learning* e confiabilidade estrutural. Foi coordenador do PPG em Engenharia Civil da UFJF e membro da Câmara de Assessoramento de Arquitetura e Engenharias da FAPEMIG e da Comissão de Avaliação das Engenharias I da CAPES (2017-2021). É pesquisador de Produtividade do CNPq desde 2013, membro do Comitê de Assessoramento do CNPq e editor de Build Engineering e Structural Sensing.

9 DETECÇÃO DE CARGAS DESBALANCEADAS EM VAGÕES FERROVIÁRIOS DE CARGA VIA APRENDIZAGEM DE MÁQUINA

Cássio Bragança¹, Rúben Silva², Edson Souza^{1,3},
Isabela Ames¹, Diogo Ribeiro⁴, Túlio Bittencourt¹

¹ Departamento de Engenharia de Estruturas e Geotécnica, Universidade de São Paulo, São Paulo, Brasil.

² CONSTRUCT-LESE, Faculdade de Engenharia, Universidade do Porto, Porto, Portugal.

³ Departamento de Engenharia Civil, Universidade Tecnológica Federal do Paraná, Guarapuava, Brasil.

⁴ CONSTRUCT-LESE, Escola de Engenharia, Politécnico do Porto, Porto, Portugal.

9.1 Resumo

Cargas desbalanceadas em vagões ferroviários apresentam riscos à segurança do veículo e à integridade dos trilhos, intensificando o risco de descarrilamentos e acelerando o desgaste da infraestrutura ferroviária como um todo. Este estudo propõe uma metodologia robusta baseada em aprendizado de máquina para detectar e classificar desequilíbrios transversais em veículos de carga, utilizando as respostas dinâmicas dos trilhos (monitoramento *wayside*). Para este fim, métodos de extração de atributos como PCA, espectrogramas *Log-mel* e técnicas baseadas em múltiplos atributos são utilizados para a análise das respostas de aceleração e deformação nos trilhos obtidas por simulações numéricas. A metodologia aumenta a performance da detecção ao normalizar atributos para eliminar variações ambientais e operacionais e utilizar-se de fusão de dados para criar índices mais sensíveis a desbalanceamentos. Com estes índices foi possível diferenciar cenários com diferentes níveis de severidade para o desbalanceamento e avaliados em diferentes tipos de vagões de carga europeus. Diante dos resultados obtidos pôde-se constatar o potencial da metodologia como uma ferramenta de auxílio aos gestores de ativos ferroviários e a viabilidade de sua aplicação para o monitoramento em tempo real e a melhoria da segurança nas operações de transporte ferroviário de carga de formas escalável e não invasiva.

Palavras-Chave: Cargas verticais desbalanceadas; Monitoramento *wayside*; Interação trem-trilho; Inteligência artificial.

9.2 Introdução

O crescimento expressivo do transporte ferroviário de carga, impulsionado pelo aumento contínuo de produtividade, tem demandado aumentos substanciais das cargas por eixo, comprimento e velocidade dos trens (Bernal; Spiriyagin; Cole, 2019). O aumento do número de vagões e da carga pode não apenas impactar a segurança de circulação dos veículos (Chong; Lee; Shin, 2010; Montenegro et al., 2021); mas também reduzir a relação custo-benefício das atividades de manutenção e renovação dos trilhos (Alves et al., 2015).

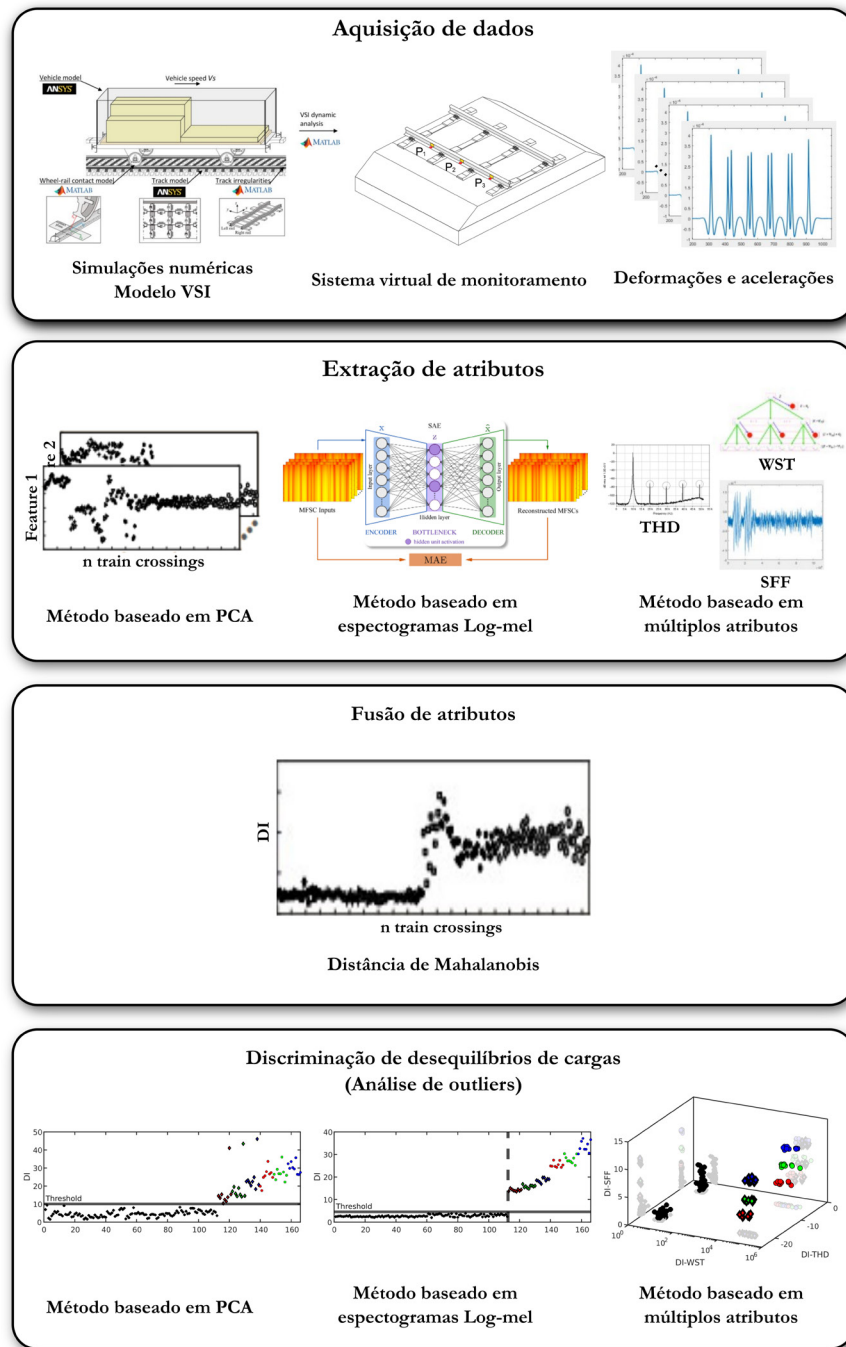
Resultante de carregamentos enviesados ou do deslocamento da carga durante o transporte; o desbalanceamento de carga nos vagões é um aspecto crucial da segurança operacional e representam a quarta maior causa de descarrilamentos nas ferrovias europeias (D-Rail, 2012; Ulianov et al., 2016). A detecção precoce de cargas desequilibradas reduz despesas de manutenção da infraestrutura ferroviária à medida que permite que os gerentes regulem os operadores (European Railway Agency, 2012).

Diante o exposto, este trabalho propõe uma metodologia de aprendizado de máquina para detectar e classificar cargas desbalanceadas, distinguindo-as de cargas uniformes, independentemente do tipo de vagão. A metodologia baseia-se nas respostas dinâmicas ferroviárias obtidas de acelerômetros e extensômetros instalados na via, seguindo quatro etapas principais: (i) extração de características; (ii) normalização de características; (iii) fusão de dados; e (iv) discriminação de características. Este estudo apresenta novas contribuições, como a consideração de tipos distintos de veículos e a capacidade de classificar diferentes severidades de cargas desbalanceadas transversalmente, introduzindo métodos mais sofisticados de extração de características.

9.3 Metodologia

A metodologia deste estudo (Figura 1) envolve quatro estágios: aquisição de dados; extração de atributos sensíveis dos sinais medidos; normalização para eliminar variações ambientais e operacionais (EOVs); fusão dos atributos para gerar índices sensíveis a distribuições anormais de carga; e análise de *outliers* para identificar eventos de desequilíbrio de carga.

Figura 1 - Visão geral da metodologia proposta



Fonte: Autores.

9.3.1 Aquisição de dados

A metodologia proposta neste trabalho, é baseada em sinais de deformação e aceleração adquiridos de uma seção monitorada da via em que os sensores estão localizados entre os dormentes em ambos os trilhos (detalhes da instrumentação virtual utilizada são explorados na Seção 9.4.2).

9.3.2 Extração de atributos

O processo de extração de características é crucial em qualquer metodologia de aprendizado de máquina visando qualquer evento de condição anormal. Ele deve remover a influência de EOVs nas respostas dinâmicas para impossibilitar a transformação de dados brutos em informações anormais sensíveis. Neste trabalho, três métodos diferentes foram investigados para avaliar a eficácia da metodologia proposta na detecção de desequilíbrios de carga, que são descritos a seguir.

9.3.2.1 Método baseado em análise de componentes principais (PCA)

No PCA-Based Method (PCABM), um PCA duplo é aplicado para extração de características e normalização. A técnica PCA é usada para obter uma redução de dimensionalidade que identifica relacionamentos importantes nos dados, por meio de uma Matriz de Covariância e por meio de uma transformação linear em componentes principais usando autovetores. Considerando uma matriz de dados de entrada \mathbf{X} ($n \times m$), os componentes principais ou pontuações podem ser calculados por:

$$\mathbf{PC} = \mathbf{X} \cdot \mathbf{T} \quad (1)$$

onde \mathbf{PC} é a matriz ($n \times m$) dos componentes principais ou pontuações, e \mathbf{T} é a matriz de transformação ortonormal linear ($m \times m$) com cada coluna sendo um autovetor de \mathbf{X} .

Preliminarmente, a matriz de dados de entrada é normalizada pelo método *Z-score*, subtraindo a média e dividindo pelo desvio-padrão para cada valor de cada coluna. A normalização antes de executar o PCA é crucial porque o PCA é altamente sensível às variâncias das variáveis iniciais. Após o cálculo do componente principal usando a Equação (1), quatro parâmetros estatísticos são extraídos dos escores do PCA: a raiz da média quadrática (RMS), o desvio-padrão (DP), a assimetria e a curtose.

A técnica PCA também é utilizada para eliminar os EOVs das respostas medidas. Assumindo que as EOVs têm um efeito linear nos atributos identificados, o método PCA pode efetivamente eliminar os efeitos dos EOVs. Além disso, as informações mais relevantes relacionadas aos efeitos operacionais e ambientais são preservadas nos primeiros eixos da PCA. O número de componentes a serem descartados é calculado pela regra comum que considera a porcentagem da variância total explicada por cada componente igual a 80% (Moshleh et al., 2022).

9.3.2.2 Método baseado em espectrogramas Log-mel

No método baseado em espectrograma *Log-mel* (LMSBM), as características cepstrais são extraídas de sinais obtidos por meio do sistema de monitoramento *wayside*. Essa técnica, introduzida por Souza et al. (2024), explora o conteúdo espaço-temporal dos espectrogramas *log-mel* do sinal (MFSC) para treinar arquiteturas de *autoencoders* esparsos profundos (SAE).

Para a extração dos MFSC, uma distorção de frequência é aplicada ao espectro de potência \mathbf{P} do sinal avaliado obtido por uma Transformada de Fourier de Tempo Curto (STFT), a fim de aprimorar as características do sinal por meio de filtros triangulares com centros igualmente espaçados numa escala de frequência Mel adaptada. A matriz do filtro passa-banda em escala Mel \mathbf{W} , com dimensão $B \times b$, consiste em B funções de filtro triangulares que se sobrepõem no domínio de baixa frequência e b compartimentos de frequência. Esses filtros triangulares são usados para enfatizar frequências que são sensíveis às cargas desbalanceadas no espectro de potência dos sinais. Isso permite a extração da matriz de \mathbf{MFSC} , definida como

$$\mathbf{MFSC} = \log(\mathbf{B} \cdot \mathbf{P}) \quad (2)$$

Para tornar a distorção Mel adequada para extração de características cepstrais no contexto de aplicações Shm, Souza et al. (2024) também introduzem uma técnica de ponderação linear. Este método emprega uma escala Mel modificada (\tilde{m}) para as frequências Hertz (f), que imita o comportamento da escala Mel até uma frequência de corte especificada, f_c , é dado por

$$\tilde{m} = \frac{8823}{2800} f_c \log\left(1 + \frac{f}{f_c}\right) \quad (3)$$

As matrizes MFSC extraídas são usadas para treinar arquiteturas SAE destinadas a selecionar atributos que são sensíveis a condições desbalanceadas. Após treinar os modelos SAE usando entradas MFSC geradas a partir de sinais obtidos durante eventos de cruzamento sob condições operacionais normais (cenários de linha de base), não se espera que o modelo reconstrua com precisão dados relacionados a cenários desbalanceados. Com isso, o erro absoluto médio (MAE) é empregado para medir o erro de reconstrução, que pode ser expresso por

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (4)$$

onde x_i e \hat{x}_i são os i -ésimos componentes correspondentes dos vetores de entrada e saída SAE, respectivamente.

Os modelos SAE para sensores de deformação e aceleração foram implementados em MATLAB®, treinados apenas em dados de base, divididos em 70% para treinamento, 20% para validação e 10% para teste. Otimizações bayesianas determinaram as arquiteturas e hiperparâmetros das redes neurais. A Tabela 1 resume as arquiteturas SAEs finais com camadas de entrada e saída com 8192 neurônios. Após isso, as características são submetidas à fusão multidimensional para criar o índice DI.

Tabela 1 – Arquitetura do SAES usado para extração de recursos

Modelo SAE	Sensor	Hiperparâmetro				
		Eras	h	λ	β	ρ
SAE-st	extensômetro	2500	2555	$1,00 \times 10^{-4}$	$3,70 \times 10^{-2}$	$1,50 \times 10^{-3}$
SAE-ac	acelerômetro	2500	1575	$1,00 \times 10^{-4}$	$5,00 \times 10^{-2}$	$8,60 \times 10^{-3}$

Fonte: Autores.

9.3.2.3 Método baseado em múltiplos recursos

No Método Baseado em Multi-Características (MFBM), uma abordagem distinta é empregada para abordar cada parte do problema: i) detecção de carga desbalanceada; ii) detecção de tipo de veículo; e iii) classificação de severidade de carga desbalanceada. Essa abordagem permite a exploração independente de cada tipo de índice. Consequentemente, três índices distintos foram propostos após análise exploratória de dados de sinais de veículos de carga com vários níveis de carga desbalanceada sob diferentes condições operacionais: DI-WST, DI-THD e DI-SFF, definidos a seguir.

DI-WST - Este índice é calculado com base no erro de reconstrução de *autoencoders* profundos com camadas LSTM (LSTM-DAE) usando os coeficientes da *Wavelet Scatering Transform* (WST) computados para cada sensor de deformação instalado na via. Inicialmente, os dados passam por um pré-processamento, onde são reamostrados em 9 pontos de dados por metro de distância percorrida pelo trem (frequência de amostragem de 100 Hz a 40 km/h). Essa taxa foi definida para representar adequadamente o fenômeno de cargas desbalanceadas, que está mais relacionado a componentes de baixa frequência, mantendo a eficiência computacional necessária para treinar os *autoencoders* e normalizar os dados em termos de velocidade do trem. Os coeficientes WST são então calculados para esses dados, usando cinco bancos de filtros *wavelet* com 20, 10, 5, 2 e 1 filtro por oitava. Além disso, uma escala de invariância de 300 amostras foi usada para garantir a invariância dos coeficientes com relação a possíveis deslocamentos de tempo.

Após calcular os coeficientes WST, os dados associados a condições de carga uniformes foram aleatoriamente permutados e divididos em conjuntos de dados de treinamento, validação e teste, em proporções de 60%, 20% e 20%, respectivamente.

Um *autoencoder* foi treinado para cada sensor e o erro de reconstrução é usado para detectar desequilíbrios de carga. Dada a natureza de tempo-frequência do WST, calcular esse erro resulta em uma matriz para cada sensor, com uma dimensão correspondendo à frequência e a outra à distância percorrida pelo trem sobre os sensores (tempo). Essas matrizes de atributos passam então por um processo de normalização baseado em PCA para remover EOVs (seção 9.3.2.1), seguido por um processo de fusão multidimensional (seção 9.3.3), para formar o índice DI WST.

DI-THD - Este índice é baseado no cálculo da Distorção Harmônica Total (THD) dos sinais de deformação coletados da via e permite diferenciar o tipo de trem. Cada tipo de composição ferroviária possui uma assinatura dinâmica no domínio da frequência, intrinsecamente ligada às características físicas do trem, como o número e o espaçamento dos eixos (Meixedo et al., 2014). A THD é capaz de distinguir diferentes tipos de veículos, pois representa um compromisso entre a frequência predominante e outras harmônicas incluídas no sinal. O cálculo da THD é realizado de acordo com a Equação 5, na qual V_{fund} é a amplitude harmônica fundamental (ordem 1) e V_h^c são as harmônicas secundárias (ordens 2, 3, ..., N). Como a assinatura dinâmica do veículo está associada à carga total aplicada na via, o desempenho do índice foi ainda mais aprimorado realizando uma decomposição de Análise de Componentes Principais (PCA) nos canais dos vários sensores e calculando a THD apenas para o primeiro componente principal. Este componente principal carrega a maior variabilidade e, conseqüentemente, o comportamento geral, o que o torna mais adequado para ser usado como base para o cálculo do índice.

$$THD = \frac{\sqrt{V_{h2}^2 + V_{h3}^2 + V_{h4}^2 + \dots + V_{hN}^2}}{V_{fund}} \quad (5)$$

DI-SFF - Finalmente, este terceiro índice é computado como o desvio-padrão dos componentes de uma decomposição PCA associada a menos de 10% de variabilidade do sinal de deformação do trilho. Normalmente, a carga desbalanceada de um vagão em uma composição está associada a uma variabilidade muito baixa no sinal geral, que se manifesta nas componentes de menor variância da decomposição PCA. Nestas componentes, a carga desigual aplicada a cada lado do trilho resulta em um desvio-padrão aumentado, que se correlaciona com a gravidade do desequilíbrio. Os desvios-padrão computados para cada componente passam por um processo de fusão, descrito na Seção 9.3.3, para formar o índice DI SFF.

9.3.3 Fusão de nível de atributos

A fusão de nível de atributos refina os atributos extraídos, destacando sua sensibilidade à condição anormal. Esta operação combina eficientemente os atributos

em um único índice. A distância de Mahalanobis (MD) foi usada, considerando o desvio de um ponto para a média de uma distribuição estatística em termos de número desvios-padrão. Isso é ideal para cenários multivariados com correlações entre atributos e grandes diferenças na escala dos atributos.

Neste estudo, a MD foi computada como uma distância de cada observação à distribuição estatística multivariada das características associadas aos cenários de linha de base, ou seja, as matrizes de média e covariância são computadas para os cenários de linha de base. Essa fusão foi aplicada em diferentes níveis para as características derivadas das três estratégias discutidas na Seção 9.3.2, a saber:

PCABM: A MD é calculada em três níveis diferentes para i) combinar os 4 parâmetros estatísticos derivados da decomposição PCA dos sinais do domínio do tempo em um único índice para cada sensor; ii) fundir os índices associados a diferentes sensores; e iii) combinar esses índices derivados dos sinais de aceleração e deformação.

LMSBM: No estágio de fusão de nível de recursos, a MD é calculada para i) integrar os recursos MAE de diferentes sensores; e ii) melhorar a sensibilidade ao desequilíbrio combinando índices de sinais de aceleração e deformação.

MFBM: Em relação aos recursos do WST, a MD foi computada para i) fundir o erro de reconstrução do WSTC em nível de frequência; ii) fundir esses resultados em nível de sensor e, finalmente; iii) fundir os índices em nível de tempo para construir um único índice (DI-WST). Em relação aos recursos estatísticos derivados da decomposição de PCA de baixa variância, a fusão é aplicada em um único nível para combinar os recursos computados para os componentes do PCA, resultando em um único índice (DI SFF), que é sensível ao desequilíbrio da gravidade da carga.

9.3.4 Discriminação de desequilíbrio

Métodos de detecção de *outliers* identificam condições anormais, destacando pontos que se desviam das amostras de dados gerais e sugerem investigação aprofundada. Na metodologia proposta, esses métodos diferenciam índices discriminantes (DIs) de casos de carga desbalanceada e de condições padrão. Observações anormais apresentam valores maiores de DI, indicando que provavelmente não pertencem à distribuição estatística de cenários de linha de base.

Um limite estatístico (TH) foi calculado a partir dos DIs do cenário de base, com base na distribuição Gaussiana cumulativa inversa por:

$$TH = \text{inv}F_x(1 - \alpha) \quad (6)$$

Onde:

$$F(x|\bar{\mu}, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{1}{2}\left(\frac{y-\bar{\mu}}{\sigma}\right)^2} dy \quad (7)$$

e é o desvio-padrão, $\bar{\mu}$ é a média e σ é o fator de significância. No escopo deste trabalho, o TH foi calculado para um nível de confiança de 99,99%, para evitar detecções de falsos positivos.

9.4 Simulação numérica

Para simular numericamente a resposta dinâmica da via sob a passagem dos veículos, matrizes estruturais da via e veículo obtidas através do software de elementos finitos ANSYS® (Ansys Inc., 2018) foram integradas por meio da ferramenta numérica “VSI - Vehicle Structure Interaction Analysis” (Montenegro et al., 2015; Neves et al., 2014).

Foram selecionados dois tipos de veículos de carga europeus amplamente utilizados, Laagrss (Bragança et al., 2022) e Sgnss (Silva et al., 2021). As suspensões foram modeladas por meio de conjuntos massa-mola e os demais elementos dos vagões foram modelados como corpos rígidos.

O modelo utilizado para a via baseou-se no trabalho desenvolvido por Silva et al. (2023), composto por camadas interconectadas por sistemas massa-mola com finalidade de representar as interfaces trilho/dormente, dormente/lastro e lastro/sublastro. Trilhos e dormentes foram modelados com elementos de viga, enquanto o lastro foi representado por elementos de massa.

Dois perfis de irregularidade baseados em funções espectrais de potência foram gerados para cada trilho nas direções vertical e transversal, com comprimentos de onda entre 1 m e 75 m discretizados a cada 0,01 m, de modo a incluir as bandas de comprimento de onda D1 (3 m a 25 m) e D2 (25 m a 70 m) conforme definido por EN 13848-2 (European Committee for Standardization, 2020).

9.4.1 Cenários de simulação

Simulações numéricas foram empregadas para validar os três métodos de extração de atributos apresentados na Seção 9.3.2 Respostas de aceleração e deformação nos trilhos foram simuladas para condições de carga uniformes e desbalanceadas. Pequenos desbalanceamentos representativos do comportamento de veículos reais e dentro dos limites de tolerância normais foram introduzidos nos cenários=base. Para gerar as configurações de carga desbalanceada, foram usados

os limites especificados pela UIC (UIC, 2022) para vagões de carga, cuja relação de carga entre as rodas esquerda e direita em um eixo deve ser inferior a 1,25:1 para desbalanceamentos transversais. Apenas cargas desbalanceadas laterais foram consideradas uma vez que altos níveis de desequilíbrios longitudinais (2:1 para Laagrss e 3:1 para Sgnss) são improváveis a esse tipo de carga. Todavia, casos de desbalanceamento longitudinal foram incluídos no cenário-base para aumentar o realismo. Ademais, um ruído de 5% foi intencionalmente introduzido nos dados simulados para replicar melhor as condições de medição reais. Todos os cenários adotados, incluindo os casos base e desbalanceados, são apresentados nas Tabelas 2 e 3, respectivamente.

Tabela 2 – Cenários de simulação de linha de base

Condição		Cinco vagões do tipo	
		SGNSS	
LAAGRSSS			
Esquemas de carregamento uniformes		Cheio/Meio cheio/Vazio	Cheio/Meio cheio/Vazio
Esquemas de carregamento ligeiramente desequilibrados	TIR	1,10:1	1,10:1/1,17:1
	LIR	1,30:1/1,60:1	1,50:1
Número de perfis de irregularidades		2	2
Velocidades		40/60/80/100/120 km/h	40/60/80/100/120 km/h
Relação de ruído		5%	5%

Abreviações: Razão de desequilíbrio transversal (TIR) e razão de desequilíbrio longitudinal (LIR).

Fonte: Autores.

Tabela 3 – Cenários de simulação desbalanceados

Condição		Cinco vagões do tipo	
		SGNSS	
LAAGRSSS			
Vagão desequilibrado		1º, 3º e 5º	1º, 3º e 5º
Esquemas de carregamento desbalanceados (sv1/sv2/sv3)	TIR	1,27:1/1,45:1/1,70:1	1,27:1/1,45:1/1,70:1
	LIR	-	-
Número de perfis de irregularidade		1	1
Velocidades		60/80/100 km/h	60/80/100 km/h
Relação de ruído		5%	5%

Abreviações: Razão de desequilíbrio transversal (TIR), razão de desequilíbrio longitudinal (LIR) e níveis de gravidade 1, 2 e 3 (sv1/sv2/sv3).


Fonte: Autores.

9.4.2 Aquisição de dados

Um sistema virtual de monitoramento *wayside* foi concebido para medir as deformações e acelerações no trilho. Este sistema compreende um conjunto de acelerômetros (A) e extensômetros (S) posicionados no vão médio do trilho entre dois

dormentes. Os acelerômetros são montados na alma do trilho, e os extensômetros são fixados na base do trilho, conforme mostrado na Figura 2.

Figura 2 – Sistema de monitoramento virtual *wayside*



Fonte: Autores.

Os dados foram coletados a uma taxa de amostragem de 10 kHz para garantir integração precisa e sinais numéricos claros, bem como cortados, filtrados e tiveram tendências lineares removidas. Para filtragem foi usado um filtro passa-baixa Chebyshev tipo II com uma frequência de corte de 500 Hz, definida por meio de análise de sensibilidade.


9.5 Resultados

O desempenho dos três métodos de extração de características foi avaliado quanto à capacidade de detecção de cargas desbalanceadas, distinção entre tipos de vagões e identificação do nível de severidade do desbalanceamento. Para os métodos PCABM e LMSBM, os índices de danos foram extraídos de sinais de deformação e aceleração e fundidos. Já no método MFBM, a fusão de dados não apresentou melhorias e somente dados de deformação foram utilizados.

9.5.1 Método baseado em PCA

Conforme a Figura 3, o índice discriminante (DI), resultante da fusão de indicadores calculados com base em aceleração e deformação pela aplicação do PCABM, apresenta baixa capacidade de detecção do desbalanceamento, sendo bem-sucedido apenas para casos mais gravosos. Percebe-se também que DI foi mais sensível a cargas desbalanceadas no Laargss do que no Sgnss.


Figura 3 – Índice discriminante computado por meio do PCABM.



9.5.2 Método baseado em espectrogramas Log-mel

O LMSBM demonstrou melhor desempenho que o PCABM em relação aos DIs obtidos como se observa na Figura 4. A metodologia forneceu distinção precisa entre condições de carga uniforme e desbalanceada, sendo sensível à gravidade do desequilíbrio e ao tipo de vagão. A fusão de dados na técnica LMSBM combinou eficientemente os benefícios dos DIs. Os SAE treinados capturaram de forma eficaz o espaço de características das respostas ferroviárias a passagens de veículos desbalanceados, gerando valores MAE de espectrogramas *Log-mel* reconstruídos sensíveis a distribuições anormais de carga operacional. As características do espectrograma Mel capturaram eficientemente as características de frequência de tempo do sinal.

Figura 4 – Índice discriminante computado por meio do LMSBM

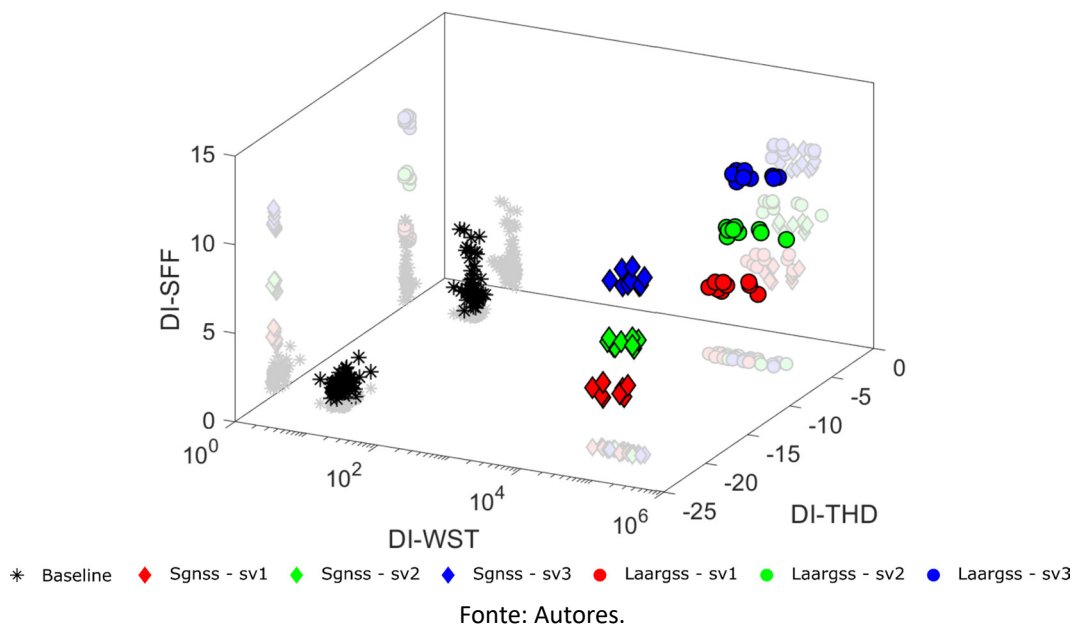


9.5.3 Método baseado em múltiplos atributos

A Figura 5 ilustra o desempenho do MFBM relativo aos três atributos distintos, cujos índices de danos descrevem eficazmente as diferentes instâncias do problema: cargas desbalanceadas (DI-WST), distinção entre desequilíbrios em diferentes tipos de vagões (DI-THD) e severidades de desbalanceamento (DI-SFF). As projeções dos

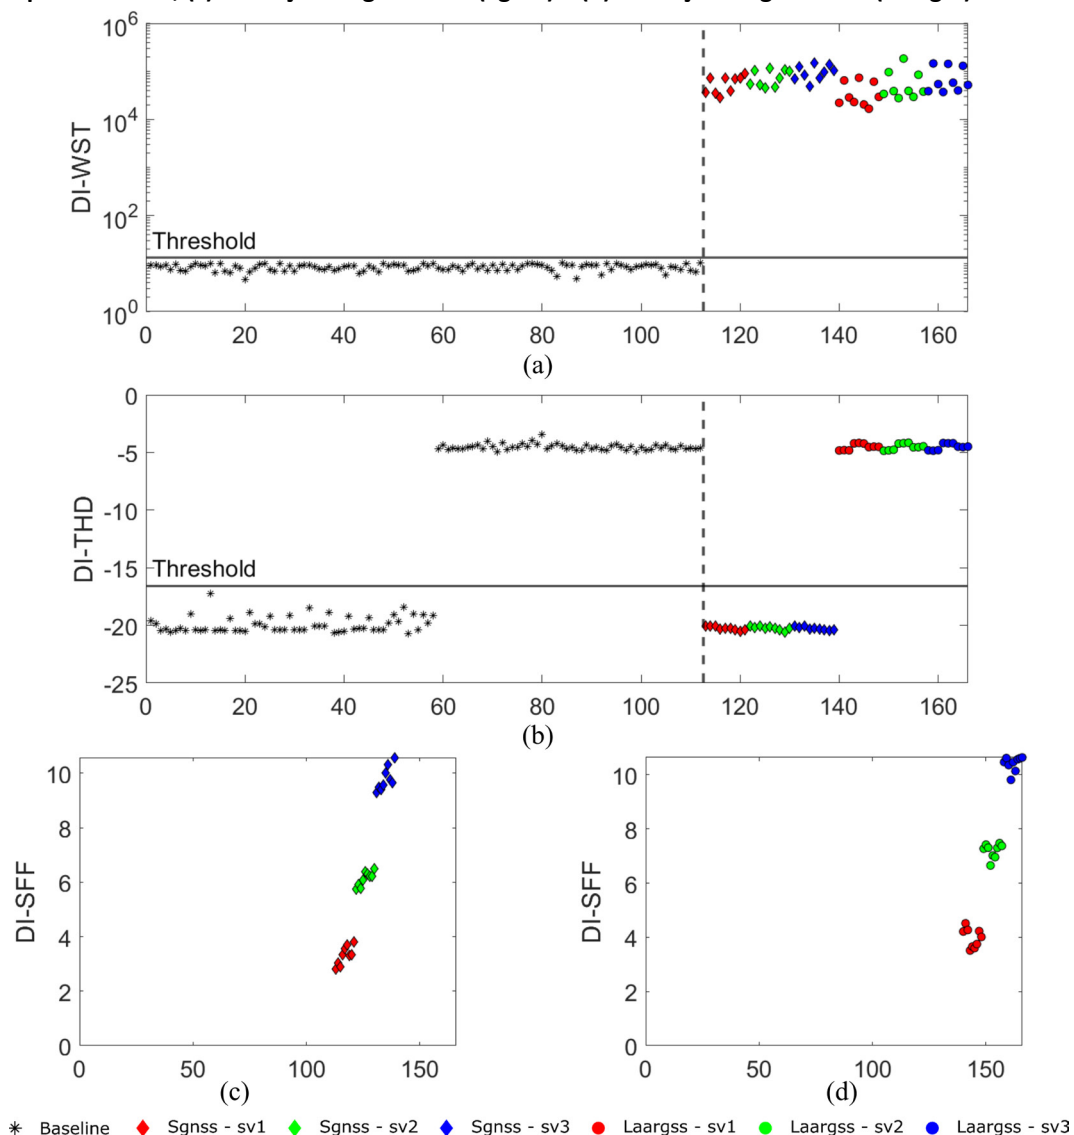
DIs nos planos coordenados (representadas em cores claras na figura) enfatizam estas. No plano DI-SFF x DI-THD, há distinção entre tipos de veículos e severidades de desequilíbrio. No plano DI-SFF x DI-WST, a detecção de cargas desbalanceadas é evidenciada. No plano DI-THD x DI-WST, a detecção distingue o desequilíbrio e os tipos de veículos.

Figura 5 – Atributos computados pelo MFBM



A Figura 6 permite, também, avaliar a vantagem da premissa de análise multiatributo da técnica. O DI baseado em WST (Figura 6a) detecta vagões desbalanceados com eficiência, mas não distingue níveis de severidade, separando condições anormais da linha de base em mais de 4 ordens de magnitude. O DI baseado em THD (Figura 6b) é o mais eficaz para distinguir tipos de vagões, enquanto o DI SFF (Figura 6c, d) agrupa severidades de desequilíbrio. O MFBM tem bom desempenho com sinais de deformação, dispensando sinais de aceleração. A robustez dos coeficientes WSCT, invariáveis a mudanças de tempo e ruído, aliada à arquitetura dos *autoencoders* baseados em redes LSTM, torna o erro de reconstrução um índice sólido para identificar anomalias.

Figura 6 – Índices discriminantes versus passagens: (a) detecção de desequilíbrio, (b) identificação do tipo de veículo, (c) avaliação da gravidade (Sgnss) e (d) avaliação da gravidade (Laargss)



Fonte: Autores.

9.6 Considerações Finais

Este capítulo apresentou uma metodologia para a detecção de cargas desbalanceadas em ferrovias por meio de aprendizado de máquina não-supervisionado. Com esta finalidade, a metodologia abrange quatro etapas – extração de atributos; normalização de atributos; fusão de dados; e discriminação de atributos. Nesse sentido, a sensibilidade de três métodos de extração de atributos foi investigada.

A metodologia foi validada a partir do estudo de dois tipos de vagões de carga tipicamente utilizados no continente europeu. A instrumentação dos trilhos foi simulada para corresponder a um esquema de monitoramento *wayside* por meio de interação veículo-via implementado em MATLAB®. Dessa forma, cenários de

carga desbalanceada, bem como cenários com carga uniforme e desbalanceamento operacionalmente tolerável, foram simulados.

Os resultados indicaram que os atributos obtidos a partir do método PCA podem detectar o desbalanceamento de carga quando esta é mais severa. Entretanto, esse atributo é ineficaz ao distinguir entre as diferentes severidades de cargas desbalanceadas. Quando o número de extensômetros é reduzido, o desempenho desse atributo é substancialmente reduzido, indicando possíveis problemas práticos de implementação.

Os atributos derivados a partir do LMSBM foram capazes de detectar efetivamente vagões desbalanceados para todas as configurações de extensômetros avaliadas, bem como distinguir entre tipos de veículo. Uma sensibilidade mais pronunciada à severidade do desbalanceamento foi observada para os atributos extraídos através de dados de aceleração, embora estes tenham apresentado casos de falsos negativos. Dessa forma, a fusão de ambos os recursos possibilita detectar o desbalanceamento e fornecer uma indicação de sua severidade.

O MFBM permite a detecção do desbalanceamento e, devido à natureza de múltiplos atributos do método, permite o agrupamento dos resultados de acordo com o tipo de veículo e nível de severidade. O DI-WST é um índice robusto na detecção de desbalanceamento, mas é apenas ligeiramente sensível à sua severidade e ao tipo de veículo. Por outro lado, o tipo de veículo pode ser distinguido com sucesso pelo índice DI-THD. O índice DI-SFF, por sua vez, é capaz de agrupar diferentes níveis de severidade. Da mesma forma que o LMSBM, o desempenho desse conjunto de atributos não é afetado pela diminuição do número de sensores, embora, ao contrário do LMSBM, essa metodologia possa ser aplicada considerando apenas dados de extensômetros.

9.7 Agradecimentos

Os autores gostariam de agradecer ao CNPq (Ministério da Ciência e Tecnologia), à CAPES (Agência de Aperfeiçoamento do Ensino Superior) e à FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) pelo apoio financeiro sob o processo n.º 2022/13045-1, VALE Cátedra Under Rail. Este trabalho foi apoiado financeiramente por: Financiamento Base - UIDB/04708/2020 com DOI 10.54499/UIDB/04708/2020 (<https://doi.org/10.54499/UIDB/04708/2020>) e Financiamento Programático - UIDP/04708/2020 com DOI 10.54499/UIDP/04708/2020 (<https://doi.org/10.54499/UIDP/04708/2020>) do CONSTRUCT - Instituto de I&D em Estruturas e Construções - financiado por fundos nacionais através da FCT/MCTES (PIDDAC).

9.8 Referências

- ALVES, Vinicius et al. Evaluation of the performance of different damage indicators in railway bridges. **Procedia Engineering**, v. 114, p. 746-753, 2015. (ISSN 1877-7058). DOI: <https://doi.org/10.1016/j.proeng.2015.08.020>.
- ANSYS INC. ANSYS® Academic Research Mechanical Release, 2018.
- BERNAL, Esteban; SPIRYAGIN, Maksym; COLE, Colin. Onboard condition monitoring sensors, systems and techniques for freight railway vehicles: a review. **IEEE Sensors Journal**, v. 19, n. 1, p. 4-24, 2019. (ISSN 1530-437X). DOI: <https://doi.org/10.1109/JSEN.2018.2875160>.
- 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. 3.024-3.050, 2022. (ISSN 0042-3114). DOI: <https://doi.org/10.1080/00423114.2021.1933091>.
- CHONG, See Yenn; LEE, Jung Ryul; SHIN, Hye Jin. A review of health and operation monitoring technologies for trains. **Smart Structures and Systems**, v. 6, n. 9, p. 1.079, 2010. (ISSN 1738-1991). DOI: <https://doi.org/10.12989/sss.2010.6.9.1079>.
- DE SOUZA, Edson Florentino et al. Drive-by damage detection methodology for high-speed railway bridges using sparse autoencoders. **Railway Engineering Science**, 2024. (ISSN 2662-4745). DOI: <https://doi.org/10.1007/s40534-024-00347-3>.
- ROBINSON, M. et al. **Summary report and database of derailments incidents (D1.1)**. Viena, 2012. Disponível em: <http://hdl.handle.net/20.500.12708/37984>. Acesso em: 31 jul. 2024.
- EUROPEAN COMMITTEE FOR STANDARDIZATION. **EN 13848-2 Railway applications - Track - Track geometry quality - Part 2: Measuring systems- Track recording vehicles**. Bruxelas: European Standard, 2020.
- EUROPEAN RAILWAY AGENCY. Prevention and mitigation of freight train derailments at short and medium terms (ERA/REP/02-2012/SAF). v. 1.0, Valenciennes: European Railway Agency, 2012. Disponível em: [https://www.era.europa.eu/system/files/2022-10/Agency's%20final%20report%20on%20the%20%20Prevention%20and%20mitigation%20of%20freight%20train%20derailments%20at%20short%20and%20medium%20terms".pdf](https://www.era.europa.eu/system/files/2022-10/Agency's%20final%20report%20on%20the%20%20Prevention%20and%20mitigation%20of%20freight%20train%20derailments%20at%20short%20and%20medium%20terms). Acesso em: 14 ago. 2024.
- MEIXEDO, A. et al. Global and local dynamic effects on a railway viaduct with precast deck. In: CIVIL-COMP PROCEEDINGS, 2014, Ajácio: Civil-Comp Press, 2014. (ISSN 1759-3433). DOI: <https://doi.org/10.4203/ccp.104.77>.

MONTENEGRO, P. A. et al. Assessment of train running safety on bridges: a literature review. **Engineering Structures**, 2021, v. 241, p. 112425. (ISSN 1873-7323). DOI: <https://doi.org/10.1016/j.engstruct.2021.112425>.

MONTENEGRO, P. et al. Wheel-rail contact formulation for analyzing the lateral train-structure dynamic interaction. **Computers and Structures**, v. 152, p. 200-214, 2015. (ISSN 0045-7949). DOI: <https://doi.org/10.1016/j.compstruc.2015.01.004>.

MOSLEH, Araliya et al. Early wheel flat detection: an automatic data-driven wavelet-based approach for railways. **Vehicle System Dynamics**, p. 1-30, 2022. (ISSN 0042-3114). DOI: <https://doi.org/10.1080/00423114.2022.2103436>.

NEVES, S. G. M. et al. A direct method for analyzing the nonlinear vehicle-structure interaction. **Engineering Structures**, v. 69, p. 83-89, 2014. (ISSN 0141-0296). DOI: <https://doi.org/10.1016/j.engstruct.2014.02.027>.

SILVA, R. et al. Early identification of unbalanced freight traffic loads based on wayside monitoring and artificial intelligence. **Sensors**, v. 23, n. 3, p. 1.544, 2023. (ISSN 1424-8220). DOI: <https://doi.org/10.3390/s23031544>.

SILVA, Rúben et al. Model updating of a freight wagon based on dynamic tests under different loading scenarios. **Applied Sciences**, v. 11, n. 22, p. 10.691, 2021. (ISSN 2076-3417). DOI: <https://doi.org/10.3390/app112210691>.

UIC. Loading Guidelines Code of practice for the loading and securing of goods on railway wagons, v. 1, Paris: União Internacional de Caminhos de Ferro (UIC), 2022.

ULIANOV, Cristian et al. Overview of freight train derailments in the EU: Causes, impacts, prevention and mitigation measures. **Traffic Safety**, v. 4, p. 317-336, 2016. DOI: <https://doi.org/10.1002/9781119307853.ch20>.

9.9 Sobre os(as) autores(as)

Cássio Bragança é Engenheiro Mecânico pela UFMG (2019) Medalha de Ouro Agnelo Macêdo. Mestre em Engenharia de Estruturas pela UFMG (2022). Atualmente, é doutorando em Engenharia Civil na Escola Politécnica da USP. Possui 5 anos de experiência profissional na área de acústica e vibrações. Possui diversas publicações em periódicos internacionais, capítulos de livro e participação em congressos e eventos científicos a nível nacional e internacional. Atua principalmente nas seguintes linhas de pesquisa: Processamento digital de sinais, acústica ambiental, dinâmica de estruturas, pontes, SHM, modelagem de sistemas ferroviários, metodologias de inspeção assistidas por UAVs, interação veículo estrutura e detecção de danos por metodologias drive-by.

Rúben Silva é mestre em Engenharia Civil (2010) pela Universidade de Aveiro e doutor em Engenharia Civil (2022) pela Universidade do Porto. Atualmente é pesquisador de pós-doutorado na Faculdade de Engenharia da Universidade do Porto (FEUP) e Membro do Instituto de I&D em Estruturas e Construção (CONSTRUCT). Os seus principais interesses de pesquisa são pontes ferroviárias, estruturas de alvenaria, inteligência artificial, identificação de danos, modelagem de sistemas ferroviários, SHM, atualização e validação de modelos numéricos. Autor de mais de 40 publicações científicas, incluindo publicações em periódicos internacionais, capítulos de livro e participação em congressos e eventos científicos a nível nacional e internacional.

Edson Souza é Engenheiro Civil (1998) e mestre em Engenharia Estruturas (2001) pela UNESP (2005); e doutorando em Engenharia Civil na Escola Politécnica da USP. Atualmente é professor adjunto do curso de Engenharia Civil da Universidade Tecnológica Federal do Paraná (UTFPR) – Câmpus Guarapuava. Possui diversas publicações em periódicos internacionais, capítulos de livro e participação em congressos e eventos científicos nacionais e internacionais e atua principalmente nas seguintes linhas de pesquisa: dinâmica das estruturas, interação dinâmica veículo-via-estrutura, monitoramento do estado de condição estrutural, identificação de danos e metodologias drive-by.

Isabela Ames é Engenheira Civil formada pela Universidade Tecnológica Federal do Paraná (2020) e mestra em Engenharia de Estruturas pela Escola Politécnica da Universidade de São Paulo (2024), onde atualmente desenvolve a sua pesquisa a nível de doutorado. Sua atuação concentra-se principalmente nas áreas de desenvolvimento de gêmeos digitais de pontes assistido por monitoramento de integridade estrutural e métodos de aprendizado de máquina, confiabilidade estrutural e otimização baseada em risco, calibração e validação de modelos numéricos, e inspeção de infraestrutura com auxílio de aeronaves remotamente pilotadas (ARPs).

Diogo Ribeiro é licenciado em Engenharia Civil (2002), mestre em Estruturas de Engenharia Civil (2005) e doutor em Engenharia Civil (2012) pela Universidade do Porto. Atualmente é professor adjunto no departamento de Engenharia Civil do Instituto Superior de Engenharia do Porto (ISEP) e membro integrado do Instituto de I&D em Estruturas e Construção (CONSTRUCT). Os seus principais interesses de pesquisa são infraestruturas ferroviárias, dinâmica de pontes ferroviárias, interação ponte-veículo, ensaios dinâmicos de estruturas, monitorização do estado de condição estrutural, identificação modal, calibração e validação de modelos, identificação de danos, metodologias drive-by, inspeção remota, visão computacional, inteligência artificial e BIM. Autor de mais de 300 publicações científicas, incluindo edição de livros, publicações em periódicos internacionais, capítulos de livro e participação em congressos e eventos científicos a nível nacional e internacional.

Túlio Bittencourt possui graduação em Engenharia Civil pela Universidade de Brasília (1984), mestrado em Engenharia Civil pela Pontifícia Universidade Católica do Rio de Janeiro (1988) e doutorado em Engenharia de Estruturas - Cornell University (1993). Tem experiência na área de Estruturas, com ênfase em Estruturas de Concreto, atuando principalmente nos seguintes temas: mecânica da fratura do concreto, modelagem computacional não-linear via método dos elementos finitos, análise experimental e monitoramento de estruturas. Autor de mais de 450 publicações científicas, incluindo edição de livros, publicações em periódicos internacionais, capítulos de livro e participação em congressos e eventos científicos a nível nacional e internacional. É também membro do ACI (American Concrete Institute), do fib (International Federation for Structural Concrete), TRB (Transportation Research Board), RILEM (International Union of Laboratories and Experts in Construction Materials, Systems and Structures), IA-FraMCoS (International Association on Fracture Mechanics of Concrete and Concrete Structures), IABSE (International Association for Bridge and Structural Engineering), e IABMAS (International Association for Bridge Maintenance and Safety).

10 APLICAÇÃO DO MÉTODO DAS SOMAS PONDERADAS E OTIMIZAÇÃO MULTIOBJETIVO EM ANÁLISE ESTRUTURAL USANDO COMPUTAÇÃO EVOLUCIONÁRIA

Walliston dos Santos Fernandes¹, Marcelo Greco²

¹Departamento de Engenharia Civil (DECIV), Universidade Federal de Ouro Preto (UFOP).

²Departamento de Engenharia Civil, Universidade Federal de Minas Gerais (UFMG).

10.1 Resumo

A Otimização Topológica de estruturas no regime estático linear considerando otimização multiobjetivo é o foco deste trabalho. Para a realização desse processo, uma formulação heurística evolucionária denominada SESO (Smoothing Evolutionary Structural Optimization) é utilizada em conjunto com o Método dos Elementos Finitos (MEF). Ao se considerar um problema multiobjetivo, é necessário também adotar uma metodologia para a ponderação das alternativas disponíveis a fim de se escolher a topologia ótima. Por isso, o Processo Hierárquico de Análise (AHP) foi abordado, uma vez que a teoria que envolve essa metodologia é capaz de lidar com a avaliação subjetiva de alternativas, segundo múltiplos critérios, de forma simples e hierárquica. Além disso, o Método das Somas Ponderadas (WSM) atua em conjunto com o AHP a fim de organizar numericamente, em termos de critério de decisão, o conjunto de alternativas disponíveis ao longo de toda a análise de otimização. Tudo isso foi implementado em um algoritmo desenvolvido em linguagem Python®, organizado sistematicamente para ser o arquivo de entrada do software livre de análise numérica no programa de análise estrutural Code-Aster® que, por sua vez, pertence ao programa de modelagem na interface Salome-Meca® o qual conta com uma interface gráfica amigável para pré e pós-processamento da análise. Assim, objetiva-se avaliar os resultados obtidos através da minimização do vetor gerado pelo WSM. Um exemplo linear é apresentado para demonstrar a aplicabilidade do modelo numérico desenvolvido.

Palavras-Chave: Otimização Multiobjetivo; Smoothing Evolutionary Structural Optimization (SESO); Analytic Hierarchy Process (AHP); Weighted Sum Method (WSM); Salome-Meca

10.2 Introdução

Otimizar seria uma maneira de encontrar uma solução adequada, de acordo com um ou mais critérios de custo, para que se possa minimizar ou maximizar determinado critério de projeto. Esse critério pode ser uma melhor relação custo-benefício para se produzir uma peça estrutural, uma significativa redução de peso da estrutura para, por exemplo, minimizar os efeitos causados por ele, uma melhor distribuição de tensões para que membros internos da estrutura não sofram possíveis esforços elevados, minimizar deslocamentos, entre outros.

Algumas vezes faz-se necessário otimizar simultaneamente um conjunto de funções que descrevem o problema, sendo esse processo denominado otimização multiobjetivo (Marler; Arora, 2004). Assim, vários critérios conflitantes podem, ou devem, ser considerados, o que nem sempre é uma tarefa simples. Por isso, a otimização multiobjetivo busca lidar com esses objetivos conflitantes através de procedimentos numéricos, a fim de se obter o resultado ótimo esperado (Odu; Charles-Owaba, 2013). Como as funções podem ser muito distintas entre si, um critério de tomada de decisão precisa, por vezes, ser realizado. Nesse ponto, tem-se o Processo Hierárquico de Análise (AHP), que é uma ferramenta eficaz para lidar com tomadas de decisões complexas, ajudando o usuário a definir prioridades para se tomar a melhor decisão. A resposta engloba valores denominados pesos, que são vinculados a cada atributo ligado às funções que descrevem o problema, sendo este procedimento a característica principal do Método das Somas Ponderadas (WSM), que é um dos métodos utilizados para resolver problemas que envolvem um conjunto discreto de alternativas que devem ser avaliadas com base em objetivos conflitantes (Beinat; Nijkamp, 1998). Dessa forma, é possível obter a solução ótima do problema, também denominada Ótimo de Pareto.

10.3 Método de Otimização SESO

SESO é uma variante do método ESO (*Evolutionary Structural Optimization*), desenvolvido por Xie e Steven (1993), sendo este um método heurístico que consiste em uma retirada gradual de elementos finitos gerados pela análise numérica estrutural, em regiões que não contribuem efetivamente para a estrutura, ou considerados “materiais ineficientes”. O processo se inicia com a discretização de toda a estrutura em uma malha fixa de elementos finitos, também chamada de design ou domínio estendido, que inclui as condições de contorno (forças, deslocamentos, cavidades e outras condições iniciais) do problema a ser resolvido iterativamente via MEF. Depois, a tensão principal é avaliada em cada elemento, e o maior valor de tensão de toda a estrutura, a tensão máxima de von Mises, é tomado como referência para ser usado na desigualdade (Eq. 1a), conforme descrito em Almeida *et al.* (2013).

$$\sigma_e^{vm} < RR_k \cdot \sigma_{i,max}^{vm} \quad (\text{Eq. 1a})$$

$$RR_{k+1} = RR_k + RE \quad (\text{Eq. 1b})$$

onde σ_e^{vm} é a tensão de von Mises equivalente do i -ésimo elemento na iteração e $\sigma_{i,max}^{vm}$ é tensão máxima atuante na estrutura na iteração “ i ”; RR_k é a Taxa de Rejeição no k -ésimo estado estacionário ($0,0 \leq RR_k \leq 1,0$), que é um parâmetro de entrada que é atualizado usando a Taxa de Evolução (RE). O processo evolutivo é definido adicionando a taxa de evolução à Taxa de Rejeição, apresentada na Eq. (1b), que é aplicada para controlar o processo de remoção da estrutura. Portanto, os elementos que satisfazem a Eq. (1a) são gradualmente removidos na malha por um processo iterativo até que um estado estacionário seja alcançado. Essa remoção é feita alterando a matriz constitutiva ao definir um valor muito pequeno para a rigidez desse elemento, o que torna esse elemento ineficiente sem a necessidade de refazer a malha no problema. No entanto, a remoção precisa ser suavizada para que não aconteçam problemas de instabilidade da malha como, por exemplo, uma região instável chamada “tabuleiro de xadrez” (ou “tabuleiro de damas”), que ocorre devido ao modelo de condicionamento ruim da matriz de rigidez, ou análise de convergência inadequada (Díaz; Sigmund, 1995; Jog; Haber, 1996). Para resolver este problema, o SESO propõe uma organização de elementos que não satisfaz a Eq. (1a) tal que ($p\%$) destes elementos são removidos e ($1-p\%$) são retornados para a estrutura. Este retorno é realizado por uma função reguladora que realiza um procedimento de suavização ou, em outras palavras, pondera elementos com maior potencial de remoção e elementos removidos que podem ser retornados para a malha. Este procedimento pode minimizar, ou mesmo eliminar, o “tabuleiro de xadrez” porque os vazios de possíveis regiões instáveis são devolvidos devido aos seus vizinhos (Fernandes et al., 2015).

10.4 Processo Hierárquico de Análise (AHP)

O Método AHP (*Analytic Hierarchy Process*), introduzido por Saaty (1980), é uma ferramenta eficaz para lidar com tomadas de decisões complexas, ajudando o usuário a definir prioridades para tomar a melhor decisão. O método também ajuda a perceber os aspectos subjetivos e objetivos de uma decisão, reduzindo problemas complexos a uma simples comparação de pares de atributos. E, além disso, o método incorpora uma técnica útil para verificação da consistência da tomada de decisão, ou seja, analisa a integridade da resposta.

Uma das principais vantagens da AHP é que a análise não exige uma amostra significativa e comparável. Os atributos, diferentes, que não podem ser diretamente comparados podem ser analisados de uma forma simples através desse método. As prioridades dos elementos de decisão comparados, em conjunto com a soma

ponderada dos pesos, fazem parte dos vetores de prioridade que devem ser obtidos para matrizes locais em todos os pontos nodais da hierarquia do método AHP, e posteriormente sintetizados em uma direção descendente dentro dessa sequência hierárquica (Srdjevic; Srdjevic, 2023).

O método AHP procura um meio de decompor o problema a partir de uma hierarquia de “subproblemas” que podem ser facilmente compreendidos e avaliados subjetivamente. As avaliações subjetivas são convertidas em valores numéricos e processadas para classificar cada alternativa em uma escala numérica.

De acordo com Baby (2013), a metodologia do AHP pode ser descrita nas seguintes etapas: a) Estruturação do modelo de decisão: construção de uma hierarquia de objetivos/critérios e alternativas; b) Inserção de alternativas: estabelecimento de prioridades entre os elementos da hierarquia; c) Comparação relativa, com uma sintetização dos resultados, incluindo níveis em que possa haver incertezas; d) Realização de análise de sensibilidade.

10.5 Método das Somas Ponderadas (WSM)

A fim de se aplicar cada peso obtido pelo método AHP no processo de otimização, o método WSM (*Weighted Sum Method*) pode ser utilizado para resolver problemas que envolvem um conjunto discreto de alternativas que devem ser avaliadas com base em objetivos conflitantes (Beinat; Nijkamp, 1998). Para qualquer dado objetivo um ou mais atributos ou critérios diferentes são usados para medir o desempenho em relação ao objetivo inicial proposto. Os atributos são, geralmente, fornecidos em diferentes unidades e, por isso, não podem ser comparados diretamente uns com os outros. No entanto, o método WSM faz com que incomparáveis atributos possam ser comparados, priorizando-os de acordo com uma atribuição adequada de pesos e, finalmente, reduzindo a quantidade de informações através da agregação de valores ponderados e padronizados. Este processo fornece não só um ranking sistemático das alternativas, mas também os pontos fortes e fracos das alternativas em destaque. Por fim, o resultado é a soma de todos os critérios, ponderados pelos respectivos pesos, gerando um ranking para cada alternativa. O menor valor entre todas as alternativas configura a minimização do problema. De acordo com Marler e Arora (2004), o método WSM é uma das abordagens mais comuns para a otimização multiobjetivo, que pode ser expresso matematicamente pela Eq. (2).

$$R_i = \sum_{j=1}^N a_{ij} w_j \quad (\text{Eq. 1a})$$

em que R_i é o valor da i -ésima alternativa, a_{ij} é o valor atual da i -ésima alternativa em termos do j -ésimo critério, e w_j é o peso ou importância do j -ésimo critério. Se todos os pesos forem positivos, a minimização da Eq. (2) representa o Ótimo de Pareto (Zadeh, 1963), ou seja, minimizar a Eq. (2) é suficiente para obter o Ótimo de Pareto. Entretanto, a formulação não fornece uma condição necessária para o Ótimo de Pareto (Zionts, 1988).


10.6 Resultado e Discussão

A calibração do modelo é feita de acordo com as condições de contorno e o índice de performance da estrutura inicial. É importante ressaltar que a retirada de elementos da malha não ocorre de forma íntegra, ou seja, a dimensão da matriz de rigidez global não se altera. Ao invés disso, aos elementos que não contribuem efetivamente para a estrutura, é atribuído uma baixa rigidez (valor próximo ao 0) e, a cada iteração, os valores são atualizados de acordo com a distribuição de tensões. Assim, quando os valores de remoção estão elevados, pode acontecer de a estrutura apresentar certa “hipostaticidade” (rompimento da estrutura, ou seja, remoção de elementos fundamentais para o modelo) em algumas iterações até que o índice de performance cancele o processo ou até mesmo retifique a estrutura ao anular o efeito hipostático, devolvendo elementos para a estrutura. Para eventuais problemas em análises estáticas, podem ser utilizadas técnicas especiais de resolução de sistemas de equações mal condicionados, como o Teorema de Lax-Milgram (Raymond, 1998), e o Método dos Mínimos Quadrados (Lai et al., 1978). Os detalhes acerca do processo de calibração podem ser obtidos em (Fernandes et al., 2017).

10.6.1 Exemplo Numérico: Roda de Trem

Este exemplo procura otimizar a melhor topologia para uma roda maciça, considerando algumas condições normalmente impostas, de acordo com a Figura 1. As dimensões indicadas (dos raios) são dadas em milímetros.

Figura 1 – Domínio inicial da roda de trem




Fonte: Autores.

Para este problema foi aproveitada a condição de simetria, ou seja, apenas $\frac{1}{4}$ do modelo foi utilizado para a realização da análise. Além disso, os dados pertinentes do modelo são os seguintes:

Malha utilizada (*mesh*): a malha gerada no Code-Aster® possui 15181 elementos do tipo TETRA4 (Figura 2);

- Módulo de Elasticidade (E): 210 GPa;
- Coeficiente de Poisson (ν): 0,3;
- Espessura (t): 30 mm;
- Volume máximo desejado (VOLMAX) = 20%;
- Remoção máxima de volume mapeado por iteração (RVOL) = 95% (5% dos elementos são devolvidos para a estrutura);
- Fator de raio de rejeição (FRR) = 1,95%;
- Fator evolucionário de rejeição (FER) = 0,95%.

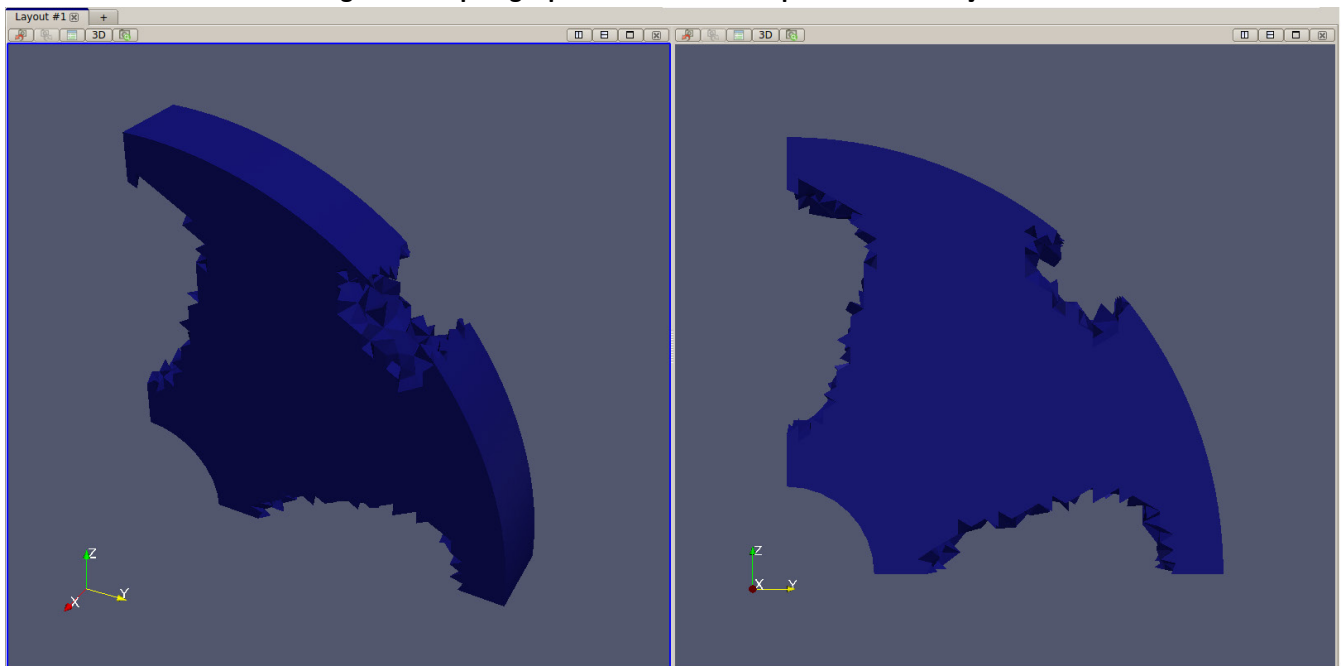
Figura 2 – Malha de elementos finitos gerada pelo Salome-Meca®



Fonte: Autores.

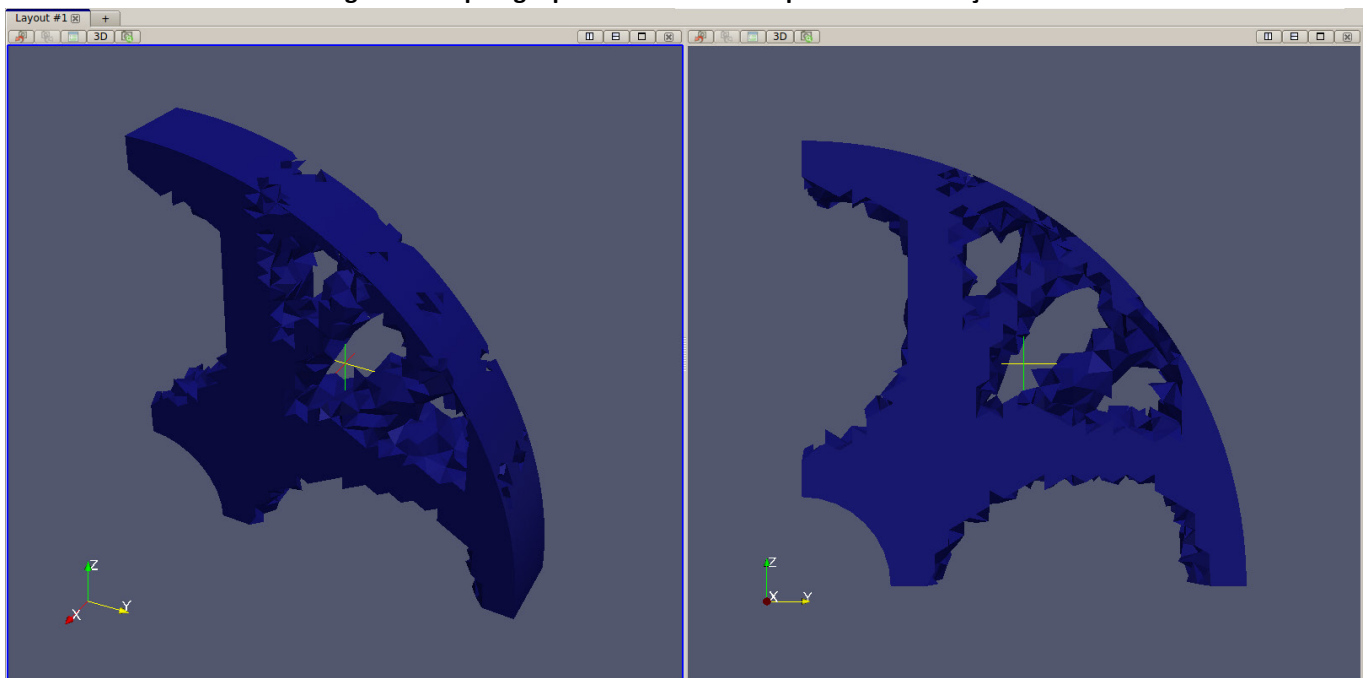
O processo evolutivo de otimização da roda de trem é mostrado a seguir, nas Figuras 3 e 4.

Figura 3 – Topologia parcial resultante do passo de otimização 6




Fonte: Autores.

Figura 4 – Topologia parcial resultante do passo de otimização 13




Fonte: Autores.

A topologia final ótima obtida para o problema é mostrada na Figura 5.

Figura 5 – Topologia final ótima resultante do passo de otimização 21

Fonte: Autores.

Como foi utilizada a condição de simetria para este exemplo, a topologia ótima final será a combinação de quatro partes da topologia obtida pelo processo de otimização, mostrada na Figura 6.

Figura 6 – Topologia final ótima completa da roda de trem

Fonte: Autores.

A Tabela 1 mostra os valores dos parâmetros e do vetor WSM. A linha em

destaque nesta tabela marca a iteração e o menor valor do vetor WSM, caracterizando a resposta da melhor topologia obtida pela análise de otimização multiobjetivo. Em seguida, tem-se na Figura 7 um gráfico que descreve o comportamento de cada um desses parâmetros ao longo do processo iterativo.


Tabela 1 – Valores dos parâmetros e do Vetor WSM

Iteração	Volume	Deslocamento (cm, %)	Tensão (MPa, %)	IP	WSM		
0	100,00	0,28	11,82	205,47	82,33	100,00	75,10
1	97,58	0,28	11,82	205,48	82,33	99,18	73,74
2	92,78	0,28	11,87	205,87	82,48	94,05	70,66
3	87,60	0,28	12,03	207,71	83,22	93,71	68,03
4	83,26	0,31	13,20	209,60	83,98	89,91	65,70
5	75,92	0,29	12,34	208,89	83,70	89,55	61,57
6	70,52	2,36	100,00	211,34	84,67	88,49	81,74
7	66,72	1,65	70,08	213,88	85,69	87,15	71,84
8	62,70	0,83	35,27	210,86	84,48	87,29	60,49
9	58,03	0,62	26,43	206,16	82,60	87,76	55,60
10	55,18	0,77	32,70	203,87	81,68	88,05	55,70
11	50,96	0,74	31,23	200,81	80,46	88,68	53,05
12	48,62	0,82	34,80	198,76	79,64	87,55	52,56
13	46,39	0,84	35,38	196,68	78,80	87,10	51,41
14	43,88	0,84	35,72	196,32	78,66	86,25	50,08
15	41,90	0,90	37,92	197,02	78,94	84,83	49,48
16	39,62	0,91	38,48	194,23	77,82	85,42	48,39
17	38,03	0,96	40,56	193,90	77,69	84,64	48,00
18	36,51	0,96	40,75	195,01	78,13	82,87	47,10
19	34,84	0,99	41,87	195,34	78,26	83,02	46,55
20	33,26	1,02	43,33	195,22	78,22	82,74	46,07
21	31,90	1,05	44,42	199,51	79,93	80,68	45,58
22	30,65	1,26	53,49	204,01	81,74	79,92	47,39
23	29,12	1,31	55,38	208,53	83,55	77,65	47,01
24	27,22	1,34	56,67	212,68	85,21	77,76	46,53
25	25,49	1,70	71,97	213,62	85,59	76,41	49,53
26	23,54	1,81	76,69	223,35	89,49	71,18	49,52
27	19,47	2,16	91,33	249,59	100,00	68,52	51,98

Fonte: Autores.

Assim como no exemplo anterior, o volume decresce suavemente ao longo de todo o processo iterativo. Quanto aos deslocamentos, na iteração 6 ocorre um pico anormal, cujo valor é o maior em toda a análise. De acordo com a Figura 3, o processo de otimização tendia para uma direção ao remover elementos da superfície da roda. Porém, estes elementos são devolvidos nas iterações seguintes, modificando o rumo de todo o processo e reduzindo novamente os valores de deslocamento no instante em que os elementos da superfície são devolvidos até a iteração 9. Na Figura 4, que corresponde à iteração 13, estes elementos já foram todos devolvidos. Após esse momento, os valores de deslocamento aumentam gradualmente até a iteração 21, onde muitos elementos já foram removidos, aumentando demasiadamente a tensão e o deslocamento. Com relação à tensão, de forma geral, a análise não apresenta grandes variações. Os valores permanecem praticamente constantes ao longo de todo o processo iterativo. O índice de performance decresce de forma suave, sem grandes variações.

Figura 7 – Parâmetros do Vetor WSM (Volume, Deslocamentos, Tensão, Índice de Performance) x Iterações




Fonte: Autores.

Para demonstrar a evolução da otimização, a Figura 8 resume o problema, mostrando os valores do vetor WSM ao longo do processo iterativo. O ponto vermelho mostra a iteração com o valor mínimo, que representa a melhor solução para o problema.

Figura 8 – Vetor do WSM x Iterações
Otimização Topológica Multiobjetivo

(Modelo Linear)



Fonte: Autores.

Neste exemplo, o vetor WSM possui valor mínimo na iteração 21, configurando esta como a solução para o conjunto de possíveis soluções para a análise. Nessa iteração, o volume é de aproximados 30% em relação ao volume inicial. Nesta iteração, o deslocamento é cerca de 2,25 vezes menor que o deslocamento máximo de toda a análise. A tensão é cerca de 1,25 vezes menor que a tensão máxima e o índice de performance se mantém nos 80%.

10.7 Considerações Finais

A importância de se otimizar está diretamente ligada ao fato de se aproveitar o máximo desempenho estrutural para determinado carregamento específico e condições iniciais. Assim, de acordo com as especificações de projeto e do ponto de vista econômico, é vantajoso otimizar um modelo para se ter uma boa relação entre o volume final da estrutura (peso) e o tipo de carregamento aplicado. Além disso, outras variáveis, como custo, podem ser relativamente melhoradas ao fim do processo. Mais do que minimizar volume, é importante uma ponderação entre a tensão máxima atuante no modelo e o deslocamento máximo ao qual a nova topologia está submetida. Em geral, quanto menor o volume da topologia, maiores serão as tensões e os deslocamentos impostos a ela. Assim, é necessário verificar quanto de volume pode ser removido sem comprometer a integridade, fixando a importância da otimização multiobjetivo.

Além disso, uma das principais vantagens da técnica de otimização topológica – SESO – é a não exigência do cálculo de gradientes da função objetivo. Segundo Gournay et al. (2008), de fato a função objetivo não está normalmente disponível para a maior parte dos problemas práticos de otimização topológica, encontrados em aplicações reais de engenharia. Ainda, o cálculo do gradiente pode ser computacionalmente caro, e para os casos em que a função objetivo apresenta descontinuidade ou funções com certo grau de complexidade, torna-se mais complicado de se obter uma resposta (Das et al., 2011). De forma geral, o fato da teoria que envolve a técnica de otimização SESO, heurística, ser simplificada em comparação com outras técnicas determinísticas e/ou probabilísticas traz uma grande vantagem no que diz respeito à implementação computacional. Ainda, a possibilidade de inserção de filtros diversos para minimizar problemas relacionados à otimização junto ao MEF, como o tabuleiro de xadrez e dependência da malha, abre um atrativo campo de estudo que dispensa relações matemáticas complexas e que garante resultados satisfatórios.

10.8 Agradecimentos

Os autores agradecem a CAPES, CNPq, UFMG, UFOP e ao grupo CIDENG, por todo o apoio na realização desta pesquisa.

10.9 Referências

ALMEIDA, V. S.; SIMONETTI, H. L.; NETO, L. O. Comparative analysis of strut-and-tie models using Smooth Evolutionary. **Engineering Structures**, v. 56, p. 1.665-1.675, 2013.

BABY, S. AHP Modeling for Multicriteria Decision-Making and to Optimise Strategies for Protecting Coastal Landscape Resources. **International Journal of Innovation, Management and Technology**, v. 4, n. 2, p. 218-227, 2013.

- BEINAT, E.; NIJKAMP, P. **Multicriteria analysis for land–use management**. 1. ed. Dordrecht: Kluwer Academic Publishers, 1998. 372 p.
- DAS, R.; JONES, R.; XIE, Y. M. Optimal topology design of industrial structures using an evolutionary algorithm. **Optimization and Engineering**, v. 12, p. 681-717, 2011.
- DÍAZ, A. R.; SIGMUND, O. Checkerboard patterns in layout optimization. **Structural and Multidisciplinary Optimization**, v. 10, p. 40-45, 1995.
- FERNANDES, W. S. et al. Topology optimization applied to 2D elasticity problems considering the geometrical nonlinearity. **Engineering Structures**, v. 100, p. 116-127, 2015.
- FERNANDES, W. S.; GRECO, M.; ALMEIDA, V. S. Application of the smooth evolutionary structural optimization method combined with a multi-criteria decision procedure. **Engineering Structures**, v. 143, p. 40-51, 2017.
- GOURNAY, F.; ALLAIRE, G.; JOUVE, F. Shape and topology optimization of the robust compliance via the level set method. **ESAIM: Control, Optimisation and Calculus of Variations**, v. 14, n. 1, p. 43-70, 2008.
- JOG, C. S.; HABER, R. B. Stability of finite element models for distributed-parameter optimization and topology design. **Computer Methods in Applied Mechanics and Engineering**, v. 130, n. 3-4, p. 203-226, 1996.
- LAI, T. L.; ROBBINS, H.; WEI, C. Z. Strong consistency of least squares estimates in multiple regression. **Journal of Multivariate Analysis**, v. 9, n. 3, p. 343-361, 1979.
- MARLER, R. T.; ARORA, J. S. Survey of multi-objective optimization methods for engineering. **Structural and Multidisciplinary Optimization**, v. 26, p. 369-395, 2004.
- ODU, G. O.; CHARLES OWABA, O. E. Review of multi-criteria optimization methods – theory and applications. **IOSR Journal of Engineering (IOSRJEN)**, v. 3, n. 10 (V2), p. 01-14, 2013.
- RAYMOND, J. S. A generalization of Lax-Milgram’s theorem. **Le Matematiche**, v. 52, n. 1, p. 147-155, 1998.
- SAATY, T. L.; VARGAS, L. G. **Models, methods, concepts and applications of the analytic hierarchy process**. 2. ed. Nova York: Springer, 2012. 345 p.
- SRDJEVIC, B.; SRDJEVIC, Z. Prioritisation in the analytic hierarchy process for real and generated comparison matrices. **Expert Systems With Applications**, v. 225, p. 120.015, 2023.

XIE, Y. M.; STEVEN, G. P. A simple evolutionary procedure for structural optimization. *Computers and Structures*, v. 49, n. 5, p. 885-896, 1993.

ZADEH, L. A. Optimality and non-scalar-valued performance criteria. **IEEE Transactions on Automatic Control**, v. 8, n. 1, p. 59-60, 1963.

ZIONTS, S. Multiple criteria mathematical programming: an updated overview and several approaches. In: **Mathematical models for decision support**. Berlim: Springer-Verlag, v. 48, p. 135-167, 1988. DOI: https://doi.org/10.1007/978-3-642-83555-1_7.

10.10 Sobre os(as) autores(as)

Walliston dos Santos Fernandes é professor na Universidade Federal de Ouro Preto (UFOP) e faz parte de dois Programas de Pós-Graduação em Engenharia Civil da UFOP, o PROPEC e o MECOM. Tem experiência na área de otimização estrutural, incluindo processos multiobjetivos, e em análises lineares e não lineares, tanto física quanto geométrica. Além disso, tem experiência em programação em diversas linguagens (Python, C++, Delphi/Lazarus, Java, Fortran, Assembly, Pascal, entre outros) e em softwares-livre, incluindo sistemas Linux/Unix.

Marcelo Greco é professor na Universidade Federal de Minas Gerais (UFMG) e faz parte do programa de pós graduação da UFMG, o PROPEEs. Tem experiência na área de Engenharia Civil, com ênfase em Estruturas, atuando principalmente nos seguintes temas: Métodos Numéricos, Análise Não Linear, Dinâmica das Estruturas, Mecânica dos Sólidos, Viscoelasticidade, Hiperelasticidade e Análise Estrutural. Atua como revisor de periódicos nacionais e internacionais desde o ano de 2007, já tendo revisado 95 artigos científicos. Atua ainda como consultor Ad Hoc do CNPq (desde 2008 com 14 pareceres emitidos) e da CAPES (desde 2012 com 2 pareceres emitidos). É autor do livro Resistência dos Materiais: uma abordagem sintética, publicado em 2016 pela Editora Elsevier.

11 TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL APLICADAS A PROBLEMAS INVERSOS EM ENGENHARIA DE ESTRUTURAS

Wanderlei Malaquias Pereira Junior¹, Fran Sérgio Lobato², Gustavo Barbosa Libotte³, Eduardo Augusto da Silva Cândido⁴, Daniel de Lima Araújo⁴, Leonardo Goliatt da Fonseca⁵

¹Faculdade de Engenharia, Universidade Federal de Catalão (UFCAT).

²Faculdade de Engenharia Química, Universidade Federal de Uberlândia (UFU).

³Instituto Politécnico, Universidade do Estado do Rio de Janeiro (UERJ).

⁴Escola de Engenharia Civil e Ambiental, Universidade Federal de Goiás (UFG).

⁵Faculdade de Engenharia, Universidade Federal de Juiz de Fora (UFJF).

11.1 Resumo

A análise inversa de problemas de que representam os fenômenos observados na natureza têm um papel fundamental no desenvolvimento científico e tecnológico nas diferentes áreas das ciências e da engenharia. Neste capítulo, técnicas de inteligência computacional são empregadas para resolver problemas inversos na área de estruturas. Foram construídos dois problemas inversos para exemplificação. O primeiro, um problema de confiabilidade inversa para determinação dos coeficientes parciais de segurança que levam a uma confiabilidade alvo. Já o segundo, um problema representa a de equação polinomial para prever deslocamentos em vigas de Euler-Bernoulli. Em linhas gerais, foi possível constatar que as metodologias empregadas foram capazes de obter boas estimativas quanto ao resultado alvo esperado.


Palavras-Chave: Inteligência computacional; Problema inverso; Estruturas.

11.2 Introdução

Problemas inversos têm ganhado crescente relevância na Engenharia, especialmente em áreas como monitoramento estrutural, geotecnia, modelagem de materiais e avaliação não destrutiva (Gallet et al., 2022).

O problema direto (também conhecido como problema de simulação) consiste em determinar as saídas (consequências ou efeitos) de um modelo (geralmente descrito por uma expressão matemática) a partir de informações de entrada (parâmetros e condições conhecidas). Por outro lado, o problema inverso é o oposto do direto, isto é; as saídas do fenômeno em análise são conhecidas e deseja-se determinar os parâmetros do modelo que melhor representam o mesmo (Silva Neto; Moura Neto, 2005), conforme apresentado na Figura 1.

Figura 1 – Representação esquemática de problemas diretos e inversos



Fonte: Autores.

Cabe destacar que no problema inverso podem ser identificados não só os parâmetros do modelo, mas também termos fontes, condições iniciais e de contorno, geometria do sistema em análise, entre outras possibilidades. Em comparação com o direto, o inverso é mais complexo, pois envolve não só a simulação, mas também a resolução de um problema de otimização (em que o objetivo é definido, geralmente, como o somatório do erro entre os valores observados e computados com a avaliação do problema de simulação).

Como mencionado por Silva Neto e Moura Neto (2005), o maior desafio durante a resolução de um problema inverso encontra-se no fato de que este é, frequentemente, mal-posto. Para que um problema seja bem-posto é necessário que: i) o problema tenha solução; ii) a solução seja única; e iii) a solução dependa continuamente dos dados observados. Assim, diz-se que um problema é mal-posto quando ele não for bem-posto.

O interesse pelo estudo de problemas inversos se deve ao fato de que, em muitas situações práticas, não é possível extrair informações sobre um sistema a partir de dados que não são diretamente observáveis. Especialmente em Engenharia Civil, na subárea de estruturas, pode-se verificar aplicações desse tipo de modelagem como por exemplo a perspectiva de monitoramento estrutural, onde é necessário determinar os elementos que têm um nível de dano estrutural a partir dos dados

de sensores de aceleração ou deslocamento (Gallet et al., 2022). Outra aplicação relevante é calibração de coeficientes parciais de segurança que são utilizados em normas de projetos estruturais. Neste contexto, o foco é estabelecer um índice de confiabilidade alvo e através de um problema inverso determinar quais os coeficientes parciais de segurança levam aqueles coeficientes parciais (Santiago et al., 2020).

Na perspectiva dos métodos de solução de problemas inversos, destacam-se os de Inteligência Computacional. A Inteligência Computacional (IC) é uma área da Inteligência Artificial que estuda aplicações envolvendo o projeto de algoritmos e sistemas em diferentes campos da ciência e engenharia (Platt et al., 2018). O uso dessas técnicas tem avançado consideravelmente, proporcionando avanços significativos na solução de problemas reais. Isto se deve à evolução da capacidade computacional e o refinamento dos algoritmos. A IC configura-se como uma ferramenta poderosa na resolução de diferentes tipos de estudos de caso, com destaque para os problemas inversos.

Conforme destacado por Silva Neto e Moura Neto (2005), um dos principais desafios durante a resolução de um problema inverso é a presença de ruídos nos dados observados, que podem tornar as soluções instáveis ou imprecisas. Neste contexto, a IC pode regularizar essas soluções, reduzindo a sensibilidade a flutuações nos dados e, ao mesmo tempo, explorando o espaço de projeto de maneira mais eficaz. Cabe enfatizar que a IC permite a integração de diferentes fontes de dados, o que é essencial em muitas áreas aplicadas, como a reconstrução de imagens médicas, onde é comum combinar dados de diferentes modalidades de exames para melhorar a precisão das soluções.

Neste caso, este estudo colabora para melhorar a compreensão da temática de um problema inverso, bem como no desenvolvimento de um problema inverso.

11.3 Evolução Diferencial

O algoritmo de Evolução Diferencial (DE) é uma estratégia de otimização baseada em população proposta por Storn e Price (1997) para problemas mono-objetivo. Esta estratégia de otimização é inspirada nos processos naturais de evolução e seleção genética, em que a atualização de um candidato à solução do problema de otimização é realizada via aplicação de operações vetoriais de soma e subtração. Neste contexto, neste algoritmo são realizadas as operações de mutação, cruzamento e seleção para que a população possa evoluir ao longo das gerações. Em linhas gerais, as principais etapas do algoritmo são:

- **Inicialização da população:** o algoritmo começa com uma população inicial de soluções, geralmente gerada aleatoriamente dentro do espaço de busca definido pelo usuário considerando os domínios para o vetor de variáveis de projeto.
- **Mutação:** para cada indivíduo da população, um vetor mutante (v) é gerado. A mutação é realizada usando uma combinação de três indivíduos (escolhidos de forma aleatória) da população. A estratégia clássica proposta por Storn e Price (1995) é descrita como:

$$v = x_1 + F(x_2 - x_3) \quad (1)$$

em que x_j ($j=1,2,3$) representa três candidatos escolhidos aleatoriamente na população, e F é a taxa de perturbação (fator de escala), cujo objetivo é controlar a amplitude da mutação.

- **Cruzamento (ou recombinação):** a recombinação é a etapa onde as informações de um vetor mutante são combinadas com o vetor de solução original para gerar um novo vetor candidato. O objetivo é explorar o espaço de busca de maneira eficiente. O cruzamento é realizado com uma probabilidade de recombinação, geralmente usando o método binário.
- **Seleção:** após a mutação e o cruzamento, a população é atualizada com a nova solução, caso a nova solução tenha um valor de função objetivo melhor. Caso contrário, o vetor original permanece na população.
- **Critério de Parada:** a população é atualizada até que um determinado critério de parada seja atingido. Normalmente, o número máximo de gerações ou a convergência da solução são os principais critérios adotados para essa finalidade.

Conforme destacado por Storn e Price (1995), o algoritmo de DE apresenta as seguintes vantagens: i) é uma abordagem simples e intuitiva (é relativamente simples de implementar e não exige muitos parâmetros, bem como as operações básicas, como mutação e cruzamento, são diretas e fáceis de entender); ii) apresenta bom desempenho em problemas de otimização multimodais (é capaz de escapar de ótimos locais); iii) a combinação entre os operadores de mutação e cruzamento permite um bom equilíbrio entre a exploração de novas regiões do espaço de busca e a exploração das regiões já descobertas; iv) o algoritmo pode ser facilmente adaptado para problemas específicos, incluindo a definição de diferentes estratégias de mutação e cruzamento; v) é capaz de lidar com funções não diferenciáveis e não lineares; e v) pode ser facilmente estendido para o contexto multi-objetivo. Por outro

lado, Storn e Price (1995), destacam as seguintes desvantagens: i) elevado custo computacional quando comparado com abordagens baseadas no uso de informações sobre derivadas; ii) o desempenho do algoritmo, para uma dada aplicação, pode ser sensível aos parâmetros; iii) assim como outras abordagens (clássicas e evolutivas), não existe garantia de convergência global; iv) o algoritmo DE pode estagnar em uma solução local e v) a solução ótima é função da diversidade inicial da população (assim como os outros algoritmos evolutivos).

11.4 Aplicações em Problemas Inversos

Para uso de uma técnica de inteligência computacional combinada a um problema inverso é necessário escrever uma função objetivo (ou função custo). No caso das funções objetivo podem variar em seu formato, mas normalmente elas se baseiam em uma função de erro entre a medida observada experimentalmente e a medida numérica obtida (Pereira Junior et al., 2021).

Nesta seção serão apresentados dois exemplos de aplicação de um problema inverso. O primeiro consiste em um problema de calibração de coeficientes parciais de segurança para normativas de projetos de estruturas. O segundo exemplo trata-se da determinação dos parâmetros de uma função polinomial que aproxima os deslocamentos de uma viga de Euler-Bernoulli.

O algoritmo de DE é considerado como otimizador: i) tamanho da população (50); ii) número de gerações (250); iii) probabilidade de cruzamento (0,8); iv) taxa de perturbação (0,8); e v) estratégia 7 para a geração de candidatos em potencial (Storn; Price, 1995). É importante ressaltar que, para inicializar o algoritmo de DE os limites foram adequados para cada um dos problemas. O algoritmo de DE foi executado 20 vezes para a apresentação dos valores médios nas tabelas que seguem. O número máximo de gerações é empregado como critério de parada. Finalmente, enfatiza-se que todos os parâmetros considerados foram definidos a partir de testes preliminares.

11.4.1 Calibração de coeficientes parciais de segurança em normas

Na concepção de uma estrutura, os requisitos técnicos referentes às condições de serviço, segurança e equilíbrio são atendidos através de um projeto e de um dimensionamento adequado, de modo a garantir um certo nível de confiabilidade. Neste sentido, considera-se então que a equação (2) é empregada para representar um problema inverso de confiabilidade onde deseja-se determinar quais os valores dos coeficientes parciais de segurança (Φ_R , γ_D , γ_L) que levam um determinado sistema estrutural a um nível de confiabilidade alvo desejado (β_{alvo}). O valor de confiabilidade calculado (β_{calc}) é dado pela avaliação da função estado limite, que caracteriza o comportamento estrutural desejado usando técnicas de confiabilidade,

no caso deste trabalho, foi utilizado a técnica de Monte Carlo, maiores detalhes em Pereira Junior et al. (2023).

$$Q = (\beta_{alvo} - \beta_{calc}(\Phi_R, \gamma_D, \gamma_L))^2 \quad (2)$$

A função objetivo deste problema é dado por Q , onde Q é o erro calculado para as medidas obtidas (β_{calc}) e medida alvo (β_{alvo}). Para a solução deste problema, empregou-se a inteligência computacional DE como o método numérico, que irá variar os valores de Φ_R , γ_D e γ_L até que se encontre os coeficientes que atinjam a medida de confiabilidade esperada (β_{alvo}). Neste caso os intervalos das variáveis de projeto foram de $[0,10; 0,99]$ para Φ_R , $[1, ;2,50]$ para as variáveis γ_D e γ_L .

Após a definição da função objetivo, define-se a função de estado limite (g). Neste trabalho, empregou-se a função descrita na equação (3) que representa o comportamento estrutural de uma viga metálica, por exemplo (Beck, 2022): em que R é a resistência do elemento, D corresponde a carga de peso próprio da estrutura e L corresponde ao carregamento de utilização da estrutura.

$$g = R - (D + L) \quad (3)$$

No caso da função estado limite, para cada variável (R , D e L), utilizou-se os valores de estatísticas percentuais utilizadas na calibração das normas norte-americanas, conforme mostra a Tabela 1.

Tabela 1 - Estatísticas de R , D e L utilizadas neste trabalho

Variável	Média	Coefficiente de Variação	Distribuição
R	1,07 R_n	0,13	Lognormal
D	1,05 D_n	0,10	Normal
L	1,00 L_n	0,25	Gumbel

Fonte: Beck (2022).

No caso deste trabalho, a relação de dimensionamento estrutural, considerando os coeficientes parciais de segurança, é dada pela equação (4). Salienta-se que este caso representa o dimensionamento ótimo, onde a capacidade estrutural de projeto (lado esquerdo) é igual a demanda de projeto (lado direito).

$$\Phi_R R_n = \gamma_D D_n + \gamma_L L_n \quad (4)$$

A equação (4) pode ser manipulada para que, a cada etapa do processo iterativo do otimizador, a nova resistência seja avaliada. Logo a equação (5) apresenta o valor da resistência (ou capacidade resistente) isolado:

$$R_n = D_n(\gamma_D + \gamma_L L_n/D_n)/\Phi_R \quad (5)$$

Maiores detalhes desta formulação podem ser vistos em Melchers e Beck (2018) e Santiago et al.(2020).

Considerando uma relação de carregamento $L/D = [0,3; 0,5; 1,0]$ e que, no caso deste trabalho, foi adotado um carregamento unitário $D = 1$ e um índice de confiabilidade alvo (β_{alvo}) igual a 3, chega-se aos coeficientes parciais de segurança apresentados na Tabela 2.

Tabela 2 - Coeficientes de segurança obtidos após a calibração por meio de problema inverso

L/D	$\Phi_{R'}$	γ_D	γ_L	β alcançado na otimização
0,30	0,81	1,13	2,14	3,04
0,50	0,95	1,73	1,44	3,09
1,00	0,97	1,72	1,64	3,01

Fonte: Autores.

Observando a Tabela 2, foi possível notar que o otimizador foi capaz de alcançar resultados de coeficientes parciais de segurança que reproduzem um índice de confiabilidade de cerca de 3. Para a relação de carregamento $L/D=0,30$ o erro foi de cerca de 3% considerando o valor alvo estabelecido.

Considerando que o menor índice de confiabilidade produzido foi para a relação $L/D=1$ aplicou-se então os coeficientes parciais de segurança para a equação de estado limite considerando as outras proporções de carregamento. Para uma proporção $L/D=0,30$ o índice de confiabilidade alvo alcançado foi de 3,19 enquanto para uma relação $L/D=0,50$ o índice de confiabilidade foi de 3,13. Logo, em uma possível recomendação normativa, os coeficientes parciais da relação $L/D=1$ seriam os recomendados.

11.4.2 Viga Euler-Bernoulli

Considere o modelo matemático que representa a vibração unidimensional da viga de Euler-Bernoulli fixada nas extremidades e em regime estacionário:

$$\frac{d^2}{dx^2} \left(EI(x) \frac{d^2 u(x)}{dx^2} \right) = f(x), 0 \leq x \leq 1 \quad (6)$$

$$u(0) = u(1) = \frac{du(0)}{dx} = \frac{du(1)}{dx} = 0$$

onde x é a posição (m), u é o deslocamento transversal da viga (m), $EI(x)$ é a rigidez à flexão (N.m²) e $f(x)$ (N/m) é uma carga dinâmica que se distribui ao longo do eixo da viga.

Nesta aplicação deseja-se formular e resolver um problema inverso para determinar a função $EI(x)$ considerando dados experimentais sintéticos. Inicialmente, o modelo diferencial é reescrito como:

$$\left(\frac{d^2 EI(x)}{dx^2}\right) \left(\frac{d^2 u(x)}{dx^2}\right) + 2 \left(\frac{dEI(x)}{dx}\right) \left(\frac{d^3 u(x)}{dx^3}\right) + EI(x) \left(\frac{d^4 u(x)}{dx^4}\right) = f(x) \quad (7)$$

Como pode ser observado, se $EI(x)$ for conhecida, o modelo da viga de Euler-Bernoulli é uma equação diferencial ordinária de quarta ordem. Assim, para integrar esse modelo, considera-se o Método das Diferenças Finitas com as seguintes aproximações no i -ésimo ponto dado como:

$$\frac{d^2 u(x)}{dx^2} \approx \frac{u_{i+1} - 2u_i + u_{i-1}}{\Delta x^2} \quad (8)$$

$$\frac{d^3 u(x)}{dx^3} \approx \frac{u_{i+2} - 2u_{i+1} + 2u_{i-1} - u_{i-2}}{2\Delta x^3} \quad (9)$$

$$\frac{d^4 u(x)}{dx^4} \approx \frac{u_{i+2} - 4u_{i+1} + 6u_i - 2u_{i-1} + u_{i-2}}{\Delta x^4} \quad (10)$$

em que u_i é a aproximação para a variável dependente no ponto genérico ($=1, \dots, N$; onde N é o número de pontos de discretização) e Δx é o tamanho do passo de integração, definido como sendo igual a $1/N$. Já para as derivadas primeiras, necessárias para a avaliação dos contornos, são empregadas as seguintes aproximações:

$$\left(\frac{du(0)}{dx}\right)_{i=1} \approx \frac{u_2 - u_1}{\Delta x} \quad (11)$$

$$\left(\frac{du(1)}{dx}\right)_{i=N} \approx \frac{u_N - u_{N-1}}{\Delta x} \quad (12)$$

O modelo que representa o fenômeno em análise é linear. Neste caso, ao substituir as aproximações apresentadas, o mesmo pode ser representado como $Au = b$.

Para validar a metodologia proposta para resolver o problema direto, consideram-se os seguintes pontos: i) a função $EI(x)$ é definida como sendo igual a $1 + \sin(\pi x)$; ii) conhecido o valor de $EI(x)$, a função $f(x)$ é obtida a partir da avaliação do operador diferencial dado pela equação (7); iii) diferentes números de pontos de discretização; e iv) aplicação do Método da Eliminação de Gauss para a resolução do sistema linear.

Na Tabela 3 são apresentados os resultados obtidos considerando o Método das Diferenças Finitas para diferentes números de pontos de discretização (N) no erro absoluto médio ($\bar{\mathcal{E}}$) avaliado em $x = 0,5$.

Tabela 3 – Influência do número de pontos de discretização na qualidade da solução obtida


N	$\bar{\mathcal{E}}$ (m)	N	$\bar{\mathcal{E}}$ (m)
10	$9,85 \times 10^{-2}$	250	$2,72 \times 10^{-3}$
50	$1,38 \times 10^{-2}$	500	$1,36 \times 10^{-3}$
100	$6,83 \times 10^{-3}$	1000	$6,81 \times 10^{-4}$

Fonte: Autores.

Na Tabela 3 é possível observar, como esperado, que o aumento no valor do parâmetro N implica na redução do erro absoluto médio. Isto se deve à redução do tamanho do passo de integração (Δx) o que na prática implica em uma melhor aproximação das derivadas considerando o Método das Diferenças Finitas.

Na Figura 2 são apresentados os perfis de deslocamento transversal da viga (analítico e numérico) em função do comprimento para N igual a 500. Nesta figura percebe-se, como esperado, que este número de pontos de colocação resulta em uma boa concordância entre os perfis simulados considerando a técnica numérica e o resultado analítico.

Figura 2 – Perfis de deslocamento transversal da viga em função do comprimento



Fonte: Autores.

O problema inverso proposto consiste na minimização do funcional Q , definido como sendo a minimização da diferença entre os pontos experimentais e os simulados para fins da determinação da função que representa $EI(x)$ ao longo do domínio de interesse. Matematicamente, este é definido como:

$$Q = \sum_{i=1}^n |EI^{exp}(x) - EI^{sim}(x)| \quad (13)$$

onde n representa o número total de valores experimentais, EI^{exp} e EI^{sim} representam os perfis experimentais e calculados de EI no ponto x_i pelo modelo proposto, respectivamente.

Para a presente aplicação, como não são conhecidos pontos experimentais, considera-se que a função EI é conhecida. Como consequência, o perfil de u ao longo da variável independente x pode ser computado com a resolução do problema direto. Assim, conhecendo-se o perfil de u , pode-se gerar pontos experimentais sintéticos a partir da inserção de um ruído. Do ponto de vista matemático, os pontos experimentais sintéticos são computados como:

$$u^{exp}(x_i) = u^{sim}(x_i) + r_i\sigma \quad (14)$$

em que r_i é um número aleatório definido no intervalo $[-1, 1]$ e σ é desvio-padrão associado aos erros no procedimento experimental sintético.

Para a resolução do problema inverso é importante destacar: i) o valor de N é igual a 500; ii) foram resolvidos problemas inversos considerando $\sigma=0$ (sem ruído) e com ruído ($\sigma=1\%$ e $\sigma=5\%$); iii) a função $EI(x)$ foi aproximada considerando uma função polinomial de grau q ($EI(x) = \lambda_q x^q + \lambda_{q-1} x^{q-1} + \dots + \lambda_1 x^1 + \lambda_0$); onde λ_k é o coeficiente da função polinomial); e iv) os limites das variáveis de projeto (λ_k), $k=1, \dots, q$) foram definidos dentro do intervalo $[-10; 10]$.

Na Tabela 4 são apresentados os valores médios dos parâmetros estimados pelo algoritmo de DE em função do grau da aproximação polinomial para dados sintéticos sem ruído. Neste caso, é possível observar que, independentemente do grau da aproximação considerada, o algoritmo de DE sempre convergiu para uma boa estimativa dos parâmetros (os valores dos desvios-padrão para cada variável de projeto são da ordem de 10^{-9}). Especificamente para q igual a 2, uma boa aproximação para o perfil de $EI(x)$ já é encontrada. Ao aumentar o valor de q percebe-se que a ordem do erro ainda é similar. Todavia, é importante ressaltar que ao aumentar o número de variáveis de projeto, o algoritmo de DE tende a encontrar uma função polinomial de segunda ordem. Em resumo, aumentar o grau do polinômio, para o estudo de caso em análise, faz com que o algoritmo de DE encontre mais dificuldades para estimar o valor dos parâmetros.

Tabela 4 – Parâmetros de projeto (médios) obtidos pelo algoritmo de DE em função do grau da aproximação polinomial

q	λ_4 (N/m ⁵)	λ_3 (N/m ⁴)	λ_2 (N/m ³)	λ_1 (N/m ²)	λ_0 (N/m)	Q (m)
2	-	-	-4,2483	4,2484	0,9253	$1,12 \times 10^{-5}$
3	-	$5,23 \times 10^{-4}$	-4,3276	4,3553	0,8780	$2,68 \times 10^{-4}$
4	0,3079	-0,6181	-3,8398	4,1494	9,3187	$1,84 \times 10^{-5}$

Fonte: Autores.

Na Tabela 5 são apresentados os valores médios dos parâmetros estimados pelo algoritmo de DE para uma função polinomial quadrática para dados sintéticos com e sem ruído. Nesta tabela observa-se que ao aumentar o valor do nível de ruído nos pontos experimentais sintéticos faz com que o valor do funcional Q aumente. Este resultado já era esperado visto que, ao aumentar o nível de ruído aos pontos experimentais sintéticos, o valor de Q irá aumentar em relação ao caso sem ruído. Finalmente, embora não tenham sido apresentados os valores dos desvios padrão para cada variável de projeto, estes são da ordem de 10^{-10} . Isto significa que o algoritmo de DE sempre convergiu para uma boa estimativa dos parâmetros.

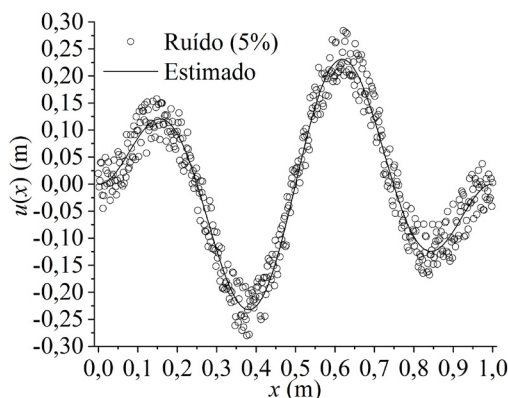
Tabela 5 – Parâmetros de projeto (médios) obtidos pelo algoritmo de DE para uma função polinomial quadrática para dados sintéticos com e sem ruído

σ (%)	λ_2 (N/m ³)	λ_1 (N/m ²)	λ_0 (N/m)	Q (m)
0	-4,2483	4,2484	0,9253	$1,12 \times 10^{-5}$
1	-4,2702	4,2705	0,9232	$1,70 \times 10^{-2}$
5	-4,3887	4,3596	0,9278	$3,99 \times 10^{-1}$

Fonte: Autores.

Já na Figura 3 são apresentados os perfis para um ruído de 5%. Nesta figura percebe-se que, embora exista o espalhamento dos pontos em relação aos pontos com $\sigma=0$, o algoritmo de DE foi capaz de encontrar uma boa estimativa para o perfil de $EI(x)$.

Figura 3 – Perfis de deslocamento transversal da viga simulados para diferentes níveis de ruído



Fonte: Autores.

11.5 Considerações Finais

O estudo demonstra a aplicabilidade da Inteligência Computacional na solução de problemas inversos, uma área de crescente relevância na engenharia civil, incluindo monitoramento estrutural e calibração de coeficientes de segurança. No contexto da análise da viga de Euler-Bernoulli, o aumento no número de pontos de discretização no Método das Diferenças Finitas leva a uma redução no erro absoluto médio na solução do problema direto. Isso indica uma melhor aproximação das derivadas com um menor passo de integração. Para o problema inverso de determinação da função que representa a rigidez à flexão da viga de Euler-Bernoulli, $EI(x)$, o algoritmo de DE conseguiu encontrar boas estimativas para este perfil mesmo com a inserção de ruído nos dados experimentais sintéticos.

Já no problema de confiabilidade estrutural foi possível perceber que o algoritmo otimizador também encontrou o valor alvo para todos os padrões de carregamento informados. No caso, um erro de cerca de 3% foi encontrado para as avaliações. Já os coeficientes parciais de segurança encontrados estão dentro dos padrões esperados para tal tipo de calibração.

Dadas essas informações, é possível constatar a robustez do método de inteligência computacional perante a problemas de natureza inversa, mostrando a versatilidade desta técnica.

Trabalhos futuros também podem explorar a utilização de funções objetivo que incorporem informações adicionais ou penalidades para garantir a estabilidade e unicidade da solução do problema inverso, especialmente considerando sua natureza frequentemente mal-posta.

11.6 Agradecimentos

Dr. Lobato agradece ao CNPq pelo apoio financeiro à sua pesquisa por meio da concessão de uma bolsa de pesquisa (processo número 309178/2023-1). Dr. Goliatt agradece o apoio financeiro das agências CNPq (processo 409433/2022-5), FAPEMIG (processos APQ-04458-23 e BPD-00083-22), FINEP (processo SOS Equipamentos 2021 AV02 0062/22) e CAPES (Código de financiamento 001).

11.7 Referências

BECK, André T. **Confiabilidade e Segurança das Estruturas**. Rio de Janeiro, Elsevier, 2017.

GALLET, A. et al. Structural engineering from an inverse problems perspective. **Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 478, 2022. Disponível em: <https://royalsocietypublishing.org/doi/10.1098/rspa.2021.0526>. Acesso em: 21 mar. 2025.

JUNIOR, W. M. Pereira et al. A proposal to use the inverse problem for determining parameters in a constitutive model for concrete. **Soft Computing**, v. 25, n. 13, p. 8.797-8.815, 2021.

MELCHERS, Robert E.; BECK, André T. **Structural reliability analysis and prediction**. 3. ed. Hoboken, NJ: John Wiley & Sons Ltd, 2018. (Engineering professional collection).

PEREIRA JUNIOR, Wanderlei Malaquias et al. Reliability analysis of reinforced concrete frames subjected to post-construction settlements. **Revista IBRACON de Estruturas e Materiais**, v. 16, n. 5, p. e16.503, 2023. Disponível em: https://www.ibracon.org.br/publicacoes/revistas_ibracon/riem/ingles/volume16_n2.asp. Acesso em: 05 maio 2025.

PLATT, Gustavo Mendes; YANG, Xin-She; SILVA NETO, Antônio José (Org.). **Computational intelligence, optimization and inverse problems with applications in engineering**. Cham: Springer International Publishing, 2019. Disponível em: <http://link.springer.com/10.1007/978-3-319-96433-1>. Acesso em: 21 mar. 2025.

SANTIAGO, Wagner Carvalho et al. Reliability-based calibration of main Brazilian structural design codes. **Latin American Journal of Solids and Structures**, v. 17, n. 1, p. e245, 2020.

SILVA NETO, Antonio Jose da; MOURA NETO, Francisco Duarte. **Problemas inversos: conceitos fundamentais e aplicações**. Rio de Janeiro: Eduerj, 2005.

STORN, Rainer; PRICE, Kenneth. Differential evolution – a simple and efficient heuristic for global optimization over continuous spaces. **Journal of Global Optimization**, v. 11, n. 4, p. 341–359, 1997. Disponível em: <https://link.springer.com/journal/10898>. Acesso em: 05 maio 2025.

11.8 Sobre os(as) autores(as)

Wanderlei Malaquias Pereira Junior é professor na Universidade Federal de Catalão (UFCAT) e docente permanente do programa de pós-graduação em Engenharia Civil da UFCAT (PPGEC/UFCAT). Tem experiência na área de aprendizagem de máquina, otimização para modelagem estrutural e confiabilidade estrutural.

Fran Sérgio Lobato é professor da Faculdade de Engenharia Química da Universidade Federal de Uberlândia, docente permanente do Programa de Pós-graduação em Modelagem e Otimização da Universidade Federal de Catalão e docente permanente do Programa de Pós-graduação em Engenharia Mecânica da

Universidade Federal de Uberlândia. Tem como áreas de interesse: i) Teoria de Controle Ótimo Algébrico-Diferencial; ii) Métodos de Otimização Clássicos e Bio-Inspirados na Natureza; iii) Atualização de parâmetros de algoritmos evolutivos; iv) Problemas Inversos; v) Projeto de Sistemas de Engenharia Multiobjetivos; vi) Tratamento de Problemas de Otimização Robustos e Baseados em Confiabilidade.

Gustavo Barbosa Libotte é professor do Departamento de Modelagem Computacional do Instituto Politécnico da Universidade do Estado do Rio de Janeiro e docente permanente do Programa de Pós-graduação em Modelagem Computacional do Instituto Politécnico. Desde 2023, é membro do experimento ATLAS, em operação no acelerador de partículas LHC, no CERN. Atuou como consultor na Avaliação de Propostas de Cursos Novos de Pós-graduação na CAPES, Área Interdisciplinar. Tem experiência na área de análise numérica e otimização estocástica, com ênfase em algoritmos evolucionários, estimação de parâmetros e análise de incerteza.

Daniel de Lima Araújo é professor titular na Universidade Federal de Goiás (UFG) e docente permanente do Programa de Pós-Graduação (mestrado e doutorado) em Geotecnia, Estruturas e Construção Civil (PPGGECON/UFG). Tem experiência em projeto e pesquisa de estruturas de concreto, atuando nas áreas de estruturas de concreto pré-moldado, concretos leves, concretos reforçados com fibras de aço e modelagem computacional.

Eduardo Augusto da Silva Cândido é mestre e doutorando em estruturas no Programa de Pós-Graduação em Geotecnia, Estruturas e Construção Civil da Universidade Federal de Goiás (PPGGECON/UFG). Tem experiência em modelagem computacional e projetos de estruturas, exercendo o cargo de engenheiro estrutural na Secretaria de Estado da Educação de Goiás. Atualmente desenvolve pesquisa na área de concretos de ultra alto desempenho reforçado com fibras de aço.

Leonardo Goliatt da Fonseca é professor na Universidade Federal de Juiz de Fora (UFJF) e docente Permanente do Programa de Pós-Graduação em modelagem Computacional da UFJF (PGMC/UFJF). Tem experiência na área de aprendizagem de máquina e ciência de dados para modelagem ambiental e energética.