

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
ENGENHARIA COMPUTACIONAL**

Pedro Henrique Eveling Oliveira

**ANÁLISE NUMÉRICA E EXPERIMENTAL DE TÉCNICAS DE
DETECÇÃO DE DANOS ESTRUTURAIS BASEADOS EM
INTELIGÊNCIA COMPUTACIONAL**

Juiz de Fora

2022

Pedro Henrique Eveling Oliveira

ANÁLISE NUMÉRICA E EXPERIMENTAL DE TÉCNICAS DE
DETECÇÃO DE DANOS ESTRUTURAIS BASEADOS EM
INTELIGÊNCIA COMPUTACIONAL

Trabalho de conclusão de curso apresentado
à Faculdade de Engenharia da Universidade
Federal de Juiz de Fora como requisito parcial
à obtenção do título de grau de bacharel em
Engenharia Computacional.

Orientador: Professor Doutor Flávio de Souza Barbosa

Juiz de Fora

2022

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

Eveling Oliveira, Pedro Henrique.

ANÁLISE NUMÉRICA E EXPERIMENTAL DE TÉCNICAS DE DETECÇÃO DE DANOS ESTRUTURAIS BASEADOS EM INTELIGÊNCIA COMPUTACIONAL / Pedro Henrique Eveling Oliveira. – 2022.

60 f. : il.

Orientador: Flávio de Souza Barbosa

Trabalho de Conclusão de Curso (graduação) – Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Engenharia Computacional, 2022.

1. Inteligência Computacional. 2. Danos Estruturais. 3. Detecção de Danos I. BARBOSA, Flávio de Souza. Título.

Pedro Henrique Eveling Oliveira

**ANÁLISE NUMÉRICA E EXPERIMENTAL DE TÉCNICAS DE
DETECÇÃO DE DANOS ESTRUTURAIS BASEADOS EM
INTELIGÊNCIA COMPUTACIONAL**

Trabalho de conclusão de curso apresentado
à Faculdade de Engenharia da Universidade
Federal de Juiz de Fora como requisito parcial
à obtenção do título de grau de bacharel em
Engenharia Computacional.

Aprovada em 14 de Fevereiro de 2022

BANCA EXAMINADORA

Professor Doutor Flávio de Souza Barbosa - Orientador
Universidade Federal de Juiz de Fora

Professor Doutor Alexandre Abrahão Cury
Universidade Federal de Juiz de Fora

Professor Doutor Leonardo Goliatt da Fonseca
Universidade Federal de Juiz de Fora

Dedico este trabalho às minhas duas mães, Dyane Sena e Vera Lúcia.

AGRADECIMENTOS

- Minha família: Por terem sido fundamentais para meu desenvolvimento desde criança. Especialmente à minha avó Vera, minha mãe Dyane, meu tio Edyson e minha tia Eliana.
- Meu orientador, Flávio Barbosa: Me deu a oportunidade da iniciação científica, me ensinou muita coisa, me ajudou a descobrir o que quero trabalhar, esteve presente e me auxiliou muito no desenvolvimento deste trabalho.
- Meus amigos: Allan Freire, Arthur Freire, Diego Marques, Douglas Barcellos, Gabriel Santos e Ramon Ferreira por não ficarem me chamando para sair (muito) durante a confecção deste trabalho. Wagner Zambelli e Vinícius Rezende pelo apoio durante todos os momentos.
- Amigos da faculdade: Arthur Gonzé e Gabriel Rezende que sofreram e foram felizes junto comigo durante o curso. Também ao Clayton da Silva, engenheiro e aluno do mestrado da engenharia civil, por me ajudar ativamente nos ensaios utilizados neste trabalho.
- Professores: Pricila Capriles que me ensinou bastante e me deu a oportunidade de participar de um projeto que me fez aprender muito. Leonardo Golliat sempre fez tudo o que era possível para me ajudar, além disso aceitou participar da banca examinadora deste trabalho.
- Equipe MegaWhat: que prestou todo apoio e fez de tudo para flexibilizar meus horários de trabalho, para que eu pudesse concluir esta etapa da minha vida. Agradeço especialmente ao Gewerton Justino e Larrissa Araiun por me entenderem e tornarem isso possível.

RESUMO

A detecção de dano ou alteração estrutural através das respostas dinâmicas é objeto de estudo de vários pesquisadores que, por décadas, tentam desenvolver tecnologias que permitam avaliar com precisão o estado de integridade da estrutura, comumente denominado de "saúde estrutural". Diversos fatores podem levar a alterações nas propriedades mecânicas de uma estrutura e, muitas vezes, essas diferenças só são visualmente perceptíveis em condições avançadas de deterioração. Uma forma de evitar isso é utilizar o monitoramento contínuo da integridade estrutural, que tem como principal objetivo detectar alterações que podem ser indícios de dano. Assim é possível informar ao operador da estrutura que existe um comportamento anormal, ainda em estágio inicial, para que providências sejam tomadas com o intuito de garantir o funcionamento do empreendimento e a segurança de seus usuários. Estes sistemas de monitoramento dependem de ferramentas computacionais eficazes para avaliar as informações que chegam continuamente da estrutura. Para este fim, técnicas baseadas em inteligência computacional têm sido apontadas como promissoras. Desta forma, neste trabalho será avaliado o uso de três métodos de Inteligência Artificial (IA) aplicados a problemas de detecção de danos em estruturas: Redes Neurais Artificiais, Máquinas de Vetor Suporte e K-vizinhos mais próximos. Os parâmetros de entrada para os algoritmos de IA são indicadores estatísticos extraídos dos sinais monitorados. As respostas dinâmicas de um pórtico plano bi-engastado ensaiado pelo autor e do caso clássico da ponte Z24 são usadas para a avaliação dos algoritmos. Os resultados obtidos indicam que estes algoritmos têm um ótimo desempenho quando aplicados a problemas de avaliação da saúde de estruturas. Finalmente, o presente estudo apresenta as vantagens e desvantagens de cada técnica analisada, abordando as perspectivas para possíveis trabalhos futuros.

ABSTRACT

The detection of damage or structural alteration through dynamic responses has been object of study of several researchers who, for decades, have tried to develop technologies to accurately assess the state of integrity of the structure, commonly called "structural health". Several factors can lead to changes in the mechanical properties of a structure and, often, these differences are only visually apparent in advanced deterioration conditions. A way to avoid this situation is using continuous monitoring of structural integrity, with the main objective of detecting changes that could be signs of damage. Therefore, it is possible to inform the structure's operator that there is an abnormal behavior, still at an early stage, so that variations can be implemented to ensure the operation of the enterprise and the safety of its users. These monitoring systems rely on effective computational tools to evaluate the information that continually arrives from the structure. In order to accomplish this, techniques based on computational intelligence have been pointed out as promising. Thus, in this work, the use of three methods of Artificial Intelligence (AI) applied to damage detection problems in structures will be evaluated: Artificial Neural Networks, Support Vector Machines and K-nearest neighbors. The input parameters for the AI algorithms are statistical indicators extracted from the monitored signals. The dynamic responses of a tested double fixed frame by the author and the classic case of the Z24 bridge are used for the evaluation of the algorithms. The results obtained indicate that these algorithms have an excellent performance when applied to structural health assessment problems. Finally, the present study informs the advantages and disadvantages of each technique that has been evaluated, approaching the perspectives for possible future work

Keywords: Structural Health. Computational Intelligence. Statistical Indicators.

LISTA DE ILUSTRAÇÕES

Figura 1 – Distrito de Bento Rodrigues após o rompimento da Barragem do Fundão.	13
Figura 2 – Vista da destruição deixada pelo rompimento da barragem de Brumadinho-MG.	14
Figura 3 – Esquema SHM simplificado	17
Figura 4 – Fluxograma da metodologia aplicada no presente trabalho	18
Figura 5 – Gráficos de duas séries temporais de sinais dinâmicos estruturais	20
Figura 6 – Representação de uma rede neural artificial com uma camada oculta .	23
Figura 7 – Exemplo de representação gráfica de uma SVM linear, com um hiperplano ótimo e duas classes.	24
Figura 8 – Conjunto de dados de exemplo para o método KNN	25
Figura 9 – Exemplos de classificações realizadas através do método KNN.	25
Figura 10 – Bancada de ensaio	27
Figura 11 – Pórtico bi-engastado em duas dimensões	28
Figura 12 – Posições dos elementos do ensaio (mm)	29
Figura 13 – Exemplo gráfico do tratamento das séries temporais e dos elementos que foram considerados.	30
Figura 14 – Matriz confusão das classificações realizadas pelos modelos (ANN) utilizando o Grupo 1 de indicadores estatísticos	32
Figura 15 – Gráfico do erro por modelo (ANN) utilizando o Grupo 1 de indicadores estatísticos	33
Figura 16 – Gráfico de tempo de execução por modelo (ANN) utilizando o Grupo 1 de indicadores estatísticos	33
Figura 17 – Matriz confusão das classificações realizadas pelos modelos (ANN) utilizando o Grupo 2 de indicadores estatísticos	34
Figura 18 – Gráfico do erro por modelo (ANN) utilizando o Grupo 2 de indicadores estatísticos	34
Figura 19 – Gráfico de tempo de execução por modelo (ANN) utilizando o Grupo 2 de indicadores estatísticos	34
Figura 20 – Matriz confusão das classificações realizadas pelos modelos (SVM) utilizando o Grupo 1 de indicadores estatísticos	35
Figura 21 – Gráfico do erro por modelo (SVM) utilizando o Grupo 1 de indicadores estatísticos	36
Figura 22 – Gráfico de tempo de execução por modelo (SVM) utilizando o Grupo 1 de indicadores estatísticos	36
Figura 23 – Matriz confusão das classificações realizadas pelos modelos (SVM) utilizando o Grupo 2 de indicadores estatísticos	36

Figura 24 – Gráfico do erro por modelo (SVM) utilizando o Grupo 2 de indicadores estatísticos	37
Figura 25 – Gráfico de tempo de execução por modelo (SVM) utilizando o Grupo 2 de indicadores estatísticos	37
Figura 26 – Matriz confusão das classificações realizadas pelos modelos (KNN) utilizando o Grupo 1 de indicadores estatísticos	38
Figura 27 – Gráfico do erro por modelo (KNN) utilizando o Grupo 1 de indicadores estatísticos	38
Figura 28 – Gráfico de tempo de execução por modelo (KNN) utilizando o Grupo 1 de indicadores estatísticos	39
Figura 29 – Matriz confusão das classificações realizadas pelos modelos (KNN) utilizando o Grupo 2 de indicadores estatísticos	39
Figura 30 – Gráfico do erro por modelo (KNN) utilizando o Grupo 2 de indicadores estatísticos	40
Figura 31 – Gráfico de tempo de execução por modelo(KNN) utilizando o Grupo 2 de indicadores estatísticos	40
Figura 32 – Gráfico do erro obtido pelos 240 modelos dos algoritmos aplicados. . .	41
Figura 33 – Gráfico do tempo obtido pelos 240 modelos dos algoritmos aplicados. .	42
Figura 34 – Fotografia da ponte Z24	43
Figura 35 – Corte transversal da ponte Z24	44
Figura 36 – Matriz confusão das classificações realizadas pelos modelos (ANN) utilizando o Grupo 1 de indicadores estatísticos	45
Figura 37 – Gráfico do erro por modelo (ANN) utilizando o Grupo 1 de indicadores estatísticos	45
Figura 38 – Gráfico de tempo de execução por modelo (ANN) utilizando o Grupo 1 de indicadores estatísticos	46
Figura 39 – Matriz confusão das classificações realizadas pelos modelos (ANN) utilizando o Grupo 2 de indicadores estatísticos	46
Figura 40 – Gráfico do erro por modelo (ANN) utilizando o Grupo 2 de indicadores estatísticos	47
Figura 41 – Gráfico de tempo de execução por modelo (ANN) utilizando o Grupo 2 de indicadores estatísticos	47
Figura 42 – Matriz confusão das classificações realizadas pelos modelos (SVM) utilizando o Grupo 1 de indicadores estatísticos	48
Figura 43 – Gráfico do erro por modelo (SVM) utilizando o Grupo 1 de indicadores estatísticos	48
Figura 44 – Gráfico de tempo de execução por modelo (SVM) utilizando o Grupo 1 de indicadores estatísticos	49

Figura 45 – Matriz confusão das classificações realizadas pelos modelos (SVM) utilizando o Grupo 2 de indicadores estatísticos	49
Figura 46 – Gráfico do erro por modelo (SVM) utilizando o Grupo 2 de indicadores estatísticos	50
Figura 47 – Gráfico de tempo de execução por modelo(SVM) utilizando o Grupo 2 de indicadores estatísticos	50
Figura 48 – Matriz confusão das classificações realizadas pelos modelos (KNN) utilizando o Grupo 1 de indicadores estatísticos	51
Figura 49 – Gráfico do erro por modelo (KNN) utilizando o Grupo 1 de indicadores estatísticos	51
Figura 50 – Gráfico de tempo de execução por modelo (KNN) utilizando o Grupo 1 de indicadores estatísticos	52
Figura 51 – Matriz confusão das classificações realizadas pelos modelos (KNN) utilizando o Grupo 2 de indicadores estatísticos	52
Figura 52 – Gráfico do erro por modelo (KNN) utilizando o Grupo 2 de indicadores estatísticos	53
Figura 53 – Gráfico de tempo de execução por modelo (KNN) utilizando o Grupo 2 de indicadores estatísticos	53
Figura 54 – Gráfico do erro obtido pelos 240 modelos dos algoritmos aplicados. . .	54
Figura 55 – Gráfico do tempo obtido pelos 240 modelos dos algoritmos aplicados. .	55

LISTA DE TABELAS

Tabela 1 – Características geométricas das barras do pórtico	27
Tabela 2 – Distribuição de massas para cada tipo de estado estrutural	29
Tabela 3 – Quantidade de ensaios para cada cenário de dano	30
Tabela 4 – Tabela dos resultados médios obtidos através das classificações	41
Tabela 5 – Tabela dos resultados médios obtidos através das classificações	54

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Contexto e motivações	13
1.2	Objetivo	15
1.3	Organização do Texto	15
2	METODOLOGIA	17
2.1	Aquisição dos sinais	19
2.2	Tratamento de sinais	19
2.3	Algoritmos de classificação	22
2.3.1	Redes neurais artificiais	22
2.3.2	Máquinas de vetores suporte (SVM - <i>Support Vector Machine</i>)	23
2.3.3	K-vizinhos mais próximos	24
3	APLICAÇÃO 1: PÓRTICO BI-ENGASTADO	27
3.1	Aquisição de Sinais	28
3.2	Tratamento dos dados	30
3.2.1	Grupo 1 de indicadores estatísticos	31
3.2.2	Grupo 2 de indicadores estatísticos	31
3.3	Classificação dos dados	31
3.3.1	Redes Neurais Artificiais	32
3.3.2	Máquinas de vetores suporte	35
3.3.3	K-vizinhos mais próximos	37
3.3.4	Comparação dos modelos	40
4	Ponte Z24	43
4.1	Aquisição dos Sinais	43
4.2	Tratamento de dados	44
4.3	Classificação de dados	44
4.3.1	Redes Neurais Artificiais	44
4.3.2	Máquinas de vetores suporte	47
4.3.3	K-vizinhos mais próximos	50
4.3.4	Comparação dos modelos	53
5	CONCLUSÕES E TRABALHOS FUTUROS	56
	REFERÊNCIAS	58

1 INTRODUÇÃO

1.1 Contexto e motivações

Toda estrutura está sujeita ao processo de deterioração que pode provocar alterações nas suas propriedades dinâmicas. Esse processo pode ocorrer por causas naturais, falhas na execução do projeto, falhas de materiais, fadiga, degradação natural ao longo do tempo, ou agentes externos como, por exemplo: Abalos sísmicos, sobrecarga, impactos, ventos, chuva, mau uso, entre outros. Um sistema estrutural deteriorado pode gerar um alto impacto econômico, social e ambiental, que vai desde uma interdição de uma ponte a um colapso de um edifício ou barragem.

No dia 5 de novembro de 2015, no subdistrito de Bento Rodrigues, próximo ao município de Mariana em Minas Gerais, uma barragem de rejeitos de mineração, conhecida como Barragem do Fundão, se rompeu. Esse desastre foi o que causou o maior impacto ambiental da história do Brasil. Foram despejados mais de 62 milhões de metros cúbicos de rejeitos, provenientes da extração do minério de ferro, que atingiram a bacia hidrográfica do Rio Doce, afetando mais de 200 municípios (Figura 1). Além do impacto ambiental e perdas de vidas humanas, prejudicou diversas atividades econômicas e o abastecimento de água da região.

Figura 1 – Distrito de Bento Rodrigues após o rompimento da Barragem do Fundão.



Fonte – UFES (1)

No dia 25 de janeiro de 2019 ocorreu o rompimento da barragem da Mina Córrego do Feijão em Brumadinho, Minas Gerais (Figura 2). Este foi o maior acidente de trabalho no Brasil em perda de vidas humanas e o segundo maior desastre industrial do século. Além disso, este desastre causou um alto impacto ambiental (2).

Estes exemplos mostram que falhas estruturais podem gerar grandes consequências e colocar a vida de pessoas em risco. A busca por tecnologias capazes de indicar o real

Figura 2 – Vista da destruição deixada pelo rompimento da barragem de Brumadinho-MG.



Fonte – G1 (2)

estado de uma estrutura faz-se necessária para evitar ou minimizar tragédias como as descritas anteriormente.

Muitas vezes um sistema estrutural pode estar na eminência de um colapso apesar de apresentar boas condições visuais. Por esse motivo, é importante que existam estratégias que permitam uma verificação para atestar a integridade da estrutura (ou, saúde estrutural). Essa avaliação pode ser feita de forma automática, com a utilização de sistemas adequados ou através de vistorias realizadas periodicamente por pessoas capacitadas. Tendo em vista as dificuldades e custos envolvidos na realização de inspeções periódicas, a busca por sistemas automatizados e capazes de realizar o monitoramento contínuo da integridade de estruturas é, hoje em dia, um dos grandes desafios da Engenharia Estrutural.

O monitoramento da integridade estrutural, conhecido pela sigla SHM (do inglês –*Structural Health Monitoring*), é o conjunto de ferramentas e métodos capazes de avaliar a saúde de uma estrutura de forma automática, partindo-se de alterações detectadas em respostas monitoradas. Sabendo-se que as modificações nas propriedades mecânicas das estruturas podem estar relacionadas ao surgimento de danos, com a utilização do SHM é possível traçar estratégias e desenvolver métodos computacionais preparados para detectá-los. O uso do SHM torna-o vantajoso por possibilitar a detecção de danos ainda em estágio inicial, permitindo que providências sejam tomadas em tempo hábil e se evite ou minimize catástrofes.

A identificação de comportamentos estruturais anormais tem sido tema relevante em pesquisas de engenharia, ganhando crescente atenção ao longo dos anos (3). Esses comportamentos anormais podem estar ligados a regiões danificadas na estrutura.

A ideia principal é que uma estrutura danificada sofre alterações em suas propriedades físicas, como massa e rigidez. Essas propriedades estão relacionadas ao comportamento

dinâmico estrutural, modificando as frequências naturais, modos de vibração e taxas de amortecimento.

Dentre as metodologias para SHM baseadas em análises da variação de parâmetros modais da estrutura se destacam: o índice MAC (Modal Assurance Criterion), que mede a correlação entre dois modos de vibração, com e sem dano (4); o SEM (Strain Energy Method) que detecta e localiza o dano baseado na análise da energia de deformação antes e depois da sua ocorrência (5); a análise da matriz de flexibilidade, que relaciona a perda de rigidez da estrutura com o aumento da flexibilidade (6); entre outros.

Por outro lado, existem outros métodos baseados em indicadores de anormalidade, que utilizam, por exemplo, análise estatística de sinais e técnicas de reconhecimento de padrões (7, 8, 9). Esses métodos podem ser vantajosos por trabalharem diretamente com as medidas dinâmicas no domínio do tempo, evitando o processo de identificação modal. Como exemplos destes métodos pode-se citar: Análise Estatística, incluindo Estatísticas de Ordem Superior (HOS - *Higher – Order Statistics*) e métodos de Inteligência Artificial (IA), como Redes Neurais Artificiais (ANN), Máquinas de Vetores Suporte (ou, do inglês SVM - *Support Vector Machine*), entre outros (10, 11, 12, 13). As estatísticas podem produzir variáveis que são capazes de caracterizar de forma compacta os sinais advindos de uma monitoração estrutural. Já os algoritmos de IA têm o papel de estabelecer padrões entre as observações, agrupando estes dados compactados de acordo com seus respectivos graus de similaridade, servindo como ferramentas para a identificação de comportamentos anormais, possivelmente associados a danos estruturais.

1.2 Objetivo

Este trabalho tem como objetivo avaliar o uso de métodos estatísticos e algoritmos de inteligência artificial aplicados às respostas dinâmicas estruturais, com intuito de indicar e classificar o estado de deterioração de estruturas.

Os dados gerados a partir dos indicadores estatísticos servirão de entrada para três algoritmos de classificação: Redes Neurais Artificiais, Máquinas de vetores suporte e K-vizinhos mais próximos. Estes últimos terão como saída um valor referente ao nível de deterioração que se encontra a estrutura analisada, numa estratégia de classificação totalmente supervisionada.

1.3 Organização do Texto

Este capítulo 1 apresenta o tema deste trabalho, objetivos e motivações.

No capítulo 2 será feita uma breve revisão dos conceitos, estratégias e métodos adotados.


As aplicações estão organizadas nos capítulos 3 e 4, onde os métodos são aplicados a dois problemas de avaliação do estado de integridade estrutural.

Por fim, no capítulo 5, estão as conclusões, sugestões para trabalhos futuros e considerações finais.

2 METODOLOGIA

O monitoramento da integridade estrutural (SHM - *Structural Health Monitoring*) é o conjunto de técnicas, métodos e estratégias que buscam monitorar continuamente uma estrutura e avaliar seu estado de integridade. Sistemas de SHM já são utilizados em algumas estruturas de grande porte no mundo (3). A ponte Rio-Niterói¹, a ponte Tsing Ma² e o viaduto de Millau³ são alguns exemplos. De forma simplificada o SHM funciona conforme a Figura 3. Esta figura mostra uma estrutura devidamente equipada com sensores para monitoramento contínuo, que fornecem dados para o sistema SHM, responsável por indicar o estado da integridade da estrutura.

Figura 3 – Esquema SHM simplificado



Fonte – Elaborado pelo autor, 2022

A utilização de um sistema SHM possui como principais vantagens (14):

- **Informações sobre o real estado da estrutura:** Em alguns casos, a estrutura pode estar com uma saúde melhor do que o esperado ou aparentemente apresentado. Assim, é possível estender o tempo de vida ou a capacidade de uma estrutura, com segurança e sem qualquer intervenção.
- **Verificação de danos em tempo hábil e melhoria da segurança:** Existem casos de estruturas em que não é possível identificar deficiências através de uma inspeção ou modelagem. Um sistema de SHM pode contribuir para uma maior rapidez na identificação de danos nas estruturas.
- **Melhoria da qualidade de execução de projeto:** Em muitos casos, os erros de execução de projeto podem levar bastante tempo para serem detectados, e isso poderá trazer um alto custo para o reparo ou diminuir a vida útil da estrutura. Um sistema de monitoramento alimentado continuamente por dados pode avaliar a saúde estrutural durante a construção, operação, manutenção e reparo, permitindo adequações não previstas no projeto.

¹ Ponte Presidente Costa e Silva, popularmente conhecida como Ponte Rio-Niterói, é uma ponte que atravessa a Baía de Guanabara, no estado do Rio de Janeiro, no Brasil.

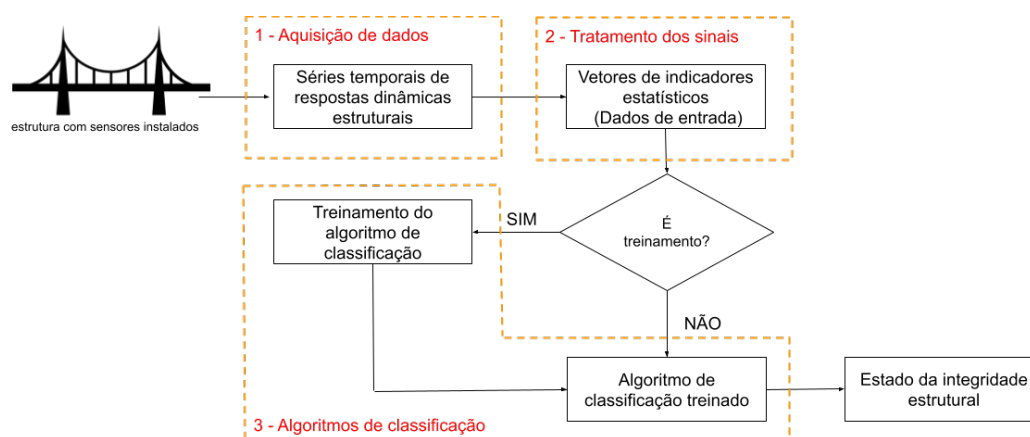
² A ponte de Tsing Ma é uma ponte pênsil situada em Hong Kong, China.

³ O Viaduto de Millau é uma grande ponte suspensa por cabos que facilita a travessia do vale do rio Tarn, próximo de Millau, no sudoeste da França.

- **Aumento do conhecimento sobre a estrutura:** Possuir dados sobre a estrutura em condições reais de operação pode ser útil para efetuar melhorias em projetos futuros e assim desenvolver sistemas estruturais mais confiáveis, seguros, e duráveis.
- **Aumento da vida útil estrutural:** Com a possibilidade de ações preventivas, planejamento de manutenções e correções estruturais, o tempo de vida útil da estrutura pode ser aumentado.
- **Redução de custos:** O custo para ações de restauração podem aumentar com o tempo, pois estão diretamente relacionadas à dimensão do dano. Se uma anomalia é detectada de forma ágil, medidas de reparo ou reforço estrutural serão menos custosas.

Neste trabalho, a metodologia pode ser dividida em três etapas destacadas na Figura 2 e resumidas a seguir:

Figura 4 – Fluxograma da metodologia aplicada no presente trabalho



Fonte – Elaborado pelo autor, 2022

1. **Aquisição de sinais:** A aquisição dos sinais é realizada através de acelerômetros instalados em pontos definidos na estrutura. Eles são conectados a um computador, que guardará as leituras dos dados vibracionais com uma frequência de aquisição definida. Esse conjunto de valores, referentes às acelerações em pontos específicos da estrutura, formam séries temporais, que relacionam as medidas de acelerações com os instantes de tempo.
2. **Tratamento de dados:** Os dados que foram captados diretamente da estrutura formam séries temporais difíceis de serem interpretadas. Além disso, são gerados milhares de valores que podem demandar muito tempo para serem avaliados. Dessa forma, é mais conveniente transformar cada série temporal em vetores de indicadores estatísticos, que já foram utilizados nos trabalhos de AMARAL(2017) (3), ALVES

et al. (10), LI et al. (11), MOUGHTY e CASAS (12) e DE LA ROSA (13). Esta estratégia é capaz de compactar as informações advindas dos sinais monitorados, possibilitando o uso de algoritmos de IA para a classificação de danos.

3. **Algoritmos de classificação:** Nesta etapa os dados já tratados tornam-se a entrada para algoritmos de classificação, que serão treinados a identificar padrões associados aos níveis de dano estrutural. Assim, a partir de uma nova entrada, o algoritmo deverá indicar o estado da estrutura. Observa-se que o procedimento de classificação ora adotado é supervisionado.

2.1 Aquisição dos sinais

A aquisição de sinais dinâmicos ocorre através de acelerômetros instalados na estrutura ensaiada. Os acelerômetros quando sujeitos a uma aceleração, geram respostas elétricas que são convertidos por um módulo conversor, que transforma a variação das tensões em dados. Estes dados são interpretados por um computador e são salvos.

Para obter diferentes estados da integridade estrutural, são simuladas condições de dano, realizando alterações físicas (retirar algum elemento estrutura, adicionar massa, por exemplo) propositalmente. Para cada alteração é feita a aquisição dos sinais dinâmicos. Estes, quando salvos, são agrupados em classes pelo tipo de dano (estado estrutural). Para aumentar a magnitude dos sinais, a estrutura ensaiada pode ser excitada de diversas formas, como: vibrações ou colisões provocadas.

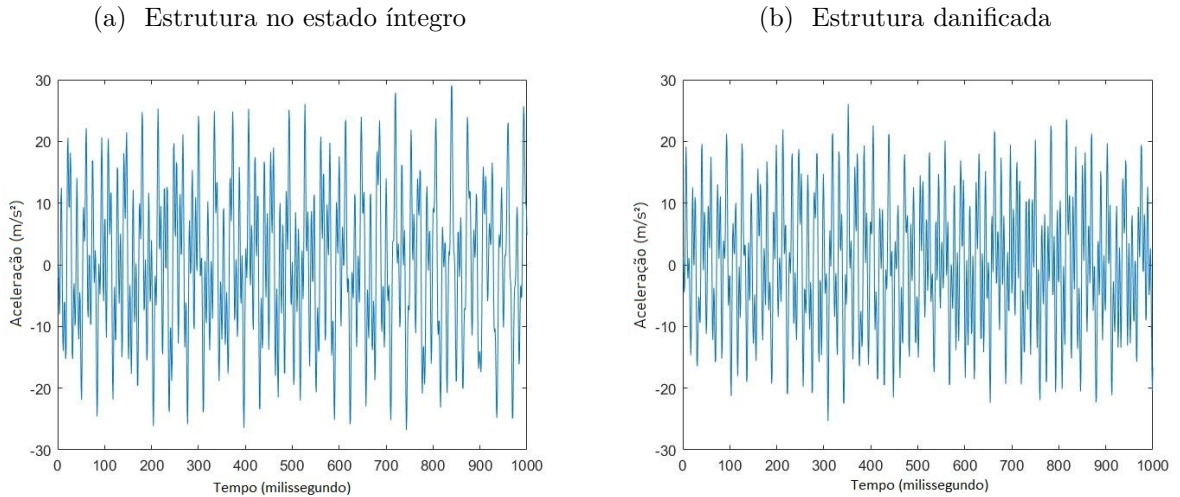
A aquisição de sinais é uma parte fundamental em qualquer estratégia para SHM. É preciso definir os sensores a serem usados, suas localizações, equipamentos para amplificar, condicionar e processar/armazenar os sinais monitorados. A modelagem computacional pode ser uma forte aliada nesta etapa, fornecendo elementos que permitam uma escolha mais adequada de sensores e suas respectivas localizações. Destaca-se que esta etapa possui diversas particularidades que são intrínsecas a cada estrutura monitorada. Assim sendo, optou-se por um maior detalhamento desta etapa nas respectivas seções do texto que apresentam os exemplos de aplicação explorados neste presente trabalho.

2.2 Tratamento de sinais

Na Figura 5 estão os gráficos de duas séries temporais, extraídas do conjunto de dados da ponte Z24 (segunda aplicação deste trabalho), representando respostas dinâmicas da estrutura em seu estado íntegro (Figura 5a), e em um estado deteriorado (Figura 5b). Conforme é possível notar existem muitas semelhanças entre os dois gráficos, o que torna praticamente impossível suas comparações diretas com intuito de identificar qual sinal se refere à estrutura íntegra e qual sinal se refere à estrutura danificada. Entretanto, ao invés de comparar diretamente os sinais, é possível definir uma série de indicadores estatísticos

que reduzam os dois sinais apresentados na Figura 5 para dois respectivos conjuntos de indicadores. A partir destes indicadores, tornam-se mais simples as comparações entres os sinais, especialmente se forem aplicados algoritmos de IA especializados em classificação de dados, o que é o caso do presente trabalho.

Figura 5 – Gráficos de duas séries temporais de sinais dinâmicos estruturais



Fonte – Elaborado pelo autor, 2020

Esses indicadores são baseados nos trabalhos de FINOTTI (15), ALVES et al. (10), LI et al. (11), MOUGHTY e CASAS (12), e DE LA ROSA (13), onde a aplicação dos mesmos levou a bons resultados para a avaliação do estado de integridade estrutura. São eles:

- **Valor de pico** (x_{pico}): Representa a maior magnitude de oscilação do sinal (x).

$$x_{pico} = \max|x| \quad (2.1)$$

- **Média** (\bar{x}), **Média Quadrática** (x_q) e **Raiz da Média Quadrática** (rms): Representam a tendência central do intervalo.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.2)$$

$$x_q = \frac{1}{n} \sum_{i=1}^n (x_i)^2 \quad (2.3)$$

$$rms = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i)^2} \quad (2.4)$$

- **Variância** (σ^2) e **Desvio Padrão** (σ): São relacionados à dispersão dos dados em torno da média.

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (2.5)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (2.6)$$

- **Assimetria (s):** Faz parte das estatísticas de ordem superior, é de 3^a ordem representa o grau de assimetria de uma distribuição de dados.

$$s = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\sigma^3} \quad (2.7)$$

- **Curtose (k):** Faz parte das estatísticas de ordem superior, é de 4^a ordem, onde significa o quanto de uma variável se encontra nas caudas da distribuição tendo como referência a distribuição normal.

$$k = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\sigma^4} \quad (2.8)$$

- **Fator de Crista (Cf) e Fator K (K):** São utilizados para identificar desvios em respostas senoidais.

$$Cf = \frac{x_{pico}}{rms} \quad (2.9)$$

$$K = x_{pico} \cdot rms \quad (2.10)$$

- **Intensidade de Arias (I_A):** A Intensidade de Arias corresponde a um método de quantificação da energia presente no acelerograma de um evento sísmico, a representa a aceleração no instante t .

$$I_A = \frac{\pi}{2g} \cdot \int_0^{\infty} a(t)^2 dt \quad (2.11)$$

- **Aceleração cumulativa absoluta (A_{cb}):** É a soma de todos os valores absolutos de aceleração.

$$A_{cb} = \sum_{i=1}^n |x_i| \quad (2.12)$$

Assim, para cada série temporal será obtido um vetor com suas respectivas estatísticas, calculada através das fórmulas apresentadas nas equações 2.1 a 2.12. Estes vetores irão integrar uma matriz de observações, que é utilizada como entrada para os algoritmos de inteligência artificial.

2.3 Algoritmos de classificação

De uma maneira geral, os algoritmos de classificação são definidos através de duas fases. A primeira, denominada de treinamento, é etapa na qual um conjunto de dados com suas respectivas saídas (classes) é apresentado ao algoritmo, visando a definição de um modelo computacional que seja capaz de captar padrões extraídos destes dados de treinamento. Em uma segunda etapa, um novo conjunto de dados, diferente daquele usado no treinamento, é apresentado ao modelo computacional treinado e espera-se que este último seja capaz de classificar corretamente o segundo conjunto dados.

Neste contexto, o problema de avaliação de integridade estrutural pode ser definido como um problema de classificação, onde as classes são definidas de acordo com o estado da estrutura no momento da aquisição dos sinais. Ou seja, a partir de um conjunto de dados para os quais já se sabe suas respectivas saídas (classe ou estado de integridade estrutural), o objetivo é classificar uma nova entrada (dados do monitoramento estrutural) através da análise da similaridade⁴ entre esta nova entrada e as classes existentes.

Existem diversos tipos de algoritmos para classificação de dados tais como: Árvores de Decisões, Máquinas de Vetor Suporte (em inglês, SVM - *Support Vector Machine*), Redes Neurais Artificiais (em inglês, ANN - *Artificial Neural Network*), K-vizinhos Mais Próximos (em inglês, KNN - *K - Nearest Neighbors*), modelos de regressão linear, entre outros. Cada um deles possui vantagens e desvantagens, e a escolha do algoritmo vai depender do objeto de estudo, conjunto de dados, necessidades e objetivos.


Tendo em vista os resultados obtidos por AMARAL(2017) (3) na sua dissertação de mestrado, optou-se por também utilizar classificadores baseados em ANN e SVM. Com o objetivo de avaliar uma terceira metodologia, analisou-se também o desempenho do algoritmo de KNN para a classificação dos dados de monitoramento estrutural. A seguir são detalhas de forma sucinta os três algoritmos de IA usados no presente trabalho. Informações mais aprofundadas podem ser encontradas nos trabalhos de EVGENIOU e PONTIL (16) para SVM, KOTHARI e HEEKUCK (17) para ANN, e CUNNINGHAM E DELANY (18) para KNN.

2.3.1 Redes neurais artificiais

As redes neurais artificiais são técnicas computacionais inspiradas na estrutura neural de organismos inteligentes, que adquirem conhecimento através de experiências. Esse tipo de algoritmo é capaz de realizar o aprendizado de máquina e reconhecimento de padrões (19).

⁴ Sinais adquiridos de uma estrutura em seu estado natural, terão semelhanças entre si, assim como os sinais adquiridos da mesma estrutura, após a ocorrência de algum dano, terão também semelhanças entre si.

Figura 6 – Representação de uma rede neural artificial com uma camada oculta



Fonte – Elaborado pelo autor, 2022

A Figura 6 traz um exemplo de como é a estrutura de uma rede neural artificial. Basicamente existe uma camada de entrada, onde são inseridos os dados do problema a serem classificados, camadas ocultas e uma camada de saída.

Existem diversos tipos de redes neurais, neste trabalho foram utilizadas redes neurais de reconhecimento de padrões, do tipo *feedforward*⁵ e utilizam *backpropagation*⁶ para ajustar o modelo. Além disso, para os treinamentos dos algoritmos de ANN foi usado o método de Levenberg–Marquardt, que é eficiente e indicado para rede neurais que possuem muitos pesos a serem ajustados (20).

2.3.2 Máquinas de vetores suporte (SVM - *Support Vector Machine*)

As máquinas de vetores suporte são algoritmos bastante populares para resolução de problemas de classificação e regressão. A ideia principal é traçar um hiperplano que separa as classes no espaço, conforme mostrado na Figura 7.

O hiperplano que separa as classes é moldado através dos vetores suporte, que são definidos pelos pontos limites de cada classe com intuito de maximizar a margem entre as regiões (26) e propiciar melhores condições para a avaliação de novas entradas, conforme é mostrado na Figura 7. Um hiperplano ótimo é o hiperplano de separação com a maior margem ele é definido como:

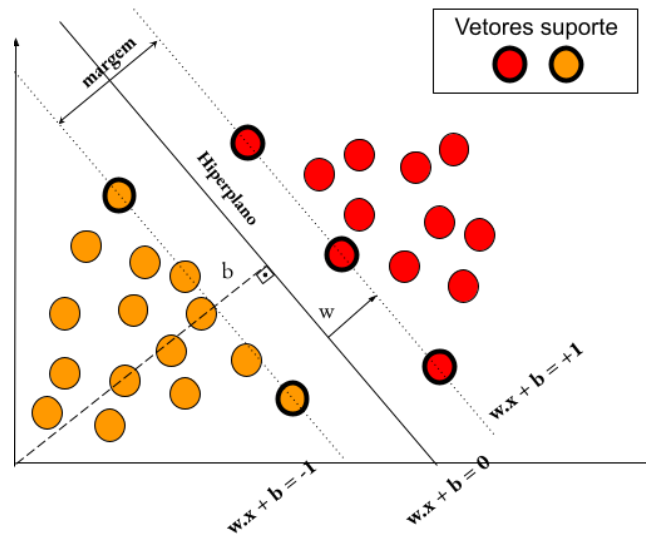
$$w \cdot x + b = 0 \quad (2.13)$$

Sendo w o vetor peso, x um vetor de variáveis de entrada, e b o bias (distância entre o hiperplano e a origem).

⁵ A informação transita em apenas uma direção, seguindo da entrada até a saída, sem caminhos de volta.

⁶ Forma que a rede é treinada, calcula o erro da saída e equilibra os pesos em todas as camadas, partindo da saída para a entrada.

Figura 7 – Exemplo de representação gráfica de uma SVM linear, com um hiperplano ótimo e duas classes.



Fonte – Elaborado pelo autor, 2022

Dado um conjunto de dados (x_i, y_i) que compõe um problema de classificação linear, sendo x_i o vetor com as variáveis de entrada, e y_i a representação da classe sua respectiva classe, e i representando o i -ésimo sinal, a função capaz de classificar os grupos é dada por:

$$w \cdot x_i + b \geq +1, \text{ para } y_i = +1 \quad (2.14)$$

$$w \cdot x_i + b \leq -1, \text{ para } y_i = -1 \quad (2.15)$$

Conforme o exemplo da Figura 7, uma entrada será classificada como vermelha se satisfizer a equação 2.14 e como laranja se satisfizer a equação 2.15.

2.3.3 K-vizinhos mais próximos

O algoritmo KNN está entre os algoritmos mais simples de aprendizagem de máquinas. Ele pode ser vantajoso para alguns problemas, obtendo ótimos resultados com um curto tempo de processamento.

São considerados basicamente dois parâmetros: O parâmetro k define a quantidade de vizinhos que serão avaliados e uma medida de similaridade calculada a partir de distâncias entre os pontos do entorno. Os cálculos de distâncias podem ser feitos de diversas formas, como através da distância Euclidiana, Mahalanobis, Manhattan, entre outras. A escolha do método para calcular as distâncias depende do tipo de problema e de como os dados estão dispostos. Para as aplicações neste trabalho será utilizada a distância Euclidiana.

O treinamento é realizado utilizando um conjunto de dados de entrada e um vetor de valores que indicam as respectivas classes dos elementos. Esses elementos são inseridos em um espaço multidimensional de acordo com o valor de cada variável. As variáveis são representadas pelas dimensões no espaço. Cada dado de entrada possui um parâmetro que o associa a uma classe. Como no treinamento esse parâmetro já é conhecido, não é necessário realizar cálculos de distâncias, nesta etapa.

Figura 8 – Conjunto de dados de exemplo para o método KNN








Figura 9 – Exemplos de classificações realizadas através do método KNN.

- (a) Inserção de uma nova entrada, para $k=3$. (b) Avaliação dos vizinhos, para $k=3$. (c) Classificação da nova entrada, para $k=3$.



- (d) Inserção de uma nova entrada, para $k=5$. (e) Avaliação dos vizinhos, para $k=5$. (f) Classificação da nova entrada, para $k=5$.



Fonte – Elaborado pelo autor, 2020

A Figura 9 mostra dois exemplos do funcionamento do algoritmo. Dado um conjunto de dados, mostrado na Figura 8, deseja-se inserir um elemento (círculo de cor verde, na Figura 9a) e classificá-lo. No primeiro exemplo para o parâmetro $k = 3$ (Figura

9a), o novo dado é inserido no espaço dos dados do problema e são calculadas todas as distâncias entre este e os pontos dentro da área de similaridade, definida pela circunferência assinalada na Figura 9b. Assim, tomando-se os três elementos mais próximos ao elemento verde, observa-se que dois deles são laranjas e um é vermelho, fazendo com que o algoritmo classifique o elemento verde como laranja, por se tratar da cor predominante (Figura 9c).


Já na Figura 9d, para $k = 5$ são avaliados os 5 pontos mais próximos, dentro da área de similaridade. Como existem 3 vermelhos e 2 laranjas, a nova entrada será classificada como vermelho (Figura 9f).

Todos os algoritmos foram executados na aplicação **Matlab** versão **R2020a**, em um computador com processadores **Intel(R) Core(TM) i5-7300HQ CPU @ 2.50GHz 2.50 GHz, 8GB - DDR4** e GPU **NVIDIA GeForce GTX 1050ti**.

3 APLICAÇÃO 1: PÓRTICO BI-ENGASTADO

Nesta aplicação todos os conjuntos de dados foram obtidos através de ensaios realizados no LIS¹ da Universidade Federal de Juiz de Fora. Para os ensaios foram utilizados um pórtico bi-engastado de alumínio, quatro acelerômetros para captar as respostas dinâmicas da estrutura e um pêndulo com uma massa de 0,014 kg, responsável por impor o carregamento à estrutura.

Figura 10 – Bancada de ensaio



Fonte – Elaborado pelo autor, 2020

O pórtico é constituído por seis barras de alumínio de módulo de elasticidade E igual a 70 GPa e massa específica ρ de 2697 kg/m^3 . A Figura 11 ilustra o pórtico bi-engastado e na Tabela 1 estão as medidas das características geométricas de cada barra que o constitui.


Tabela 1 – Características geométricas das barras do pórtico

Comprimento (mm)	Largura (mm)	Altura (mm)
300	15.875	1.587

Fonte – Elaborado pelo autor, 2020

¹ Laboratório de Imagens e Sinais do departamento de Mecânica Aplicada e Computacional da Universidade Federal de Juiz de Fora

Figura 11 – Pórtico bi-engastado em duas dimensões



Fonte – Elaborado pelo autor, 2020

3.1 Aquisição de Sinais

A aquisição dos sinais se deu através de ensaios realizados com intuito de simular diferentes estados da integridade estrutural do pórtico bi-engastado. Para isto, a estrutura foi preparada em uma bancada de ensaios e instrumentada com 4 acelerômetros piezoelétricos da marca Brüel & Kjaer IEPE com sensibilidade de 100mv/g . A frequência de aquisição escolhida foi 500 Hz, ou seja a cada 2 milissegundos é tomada uma medida de aceleração da estrutura.

Com objetivo de excitar a estrutura foi utilizado um pêndulo com uma massa acoplada na sua extremidade que tinha como objetivo, ao ser liberado do repouso, se colidir com a estrutura e fazê-la vibrar.

Sabendo-se que os danos estruturais tendem a reduzir as frequências naturais da estrutura (3), optou-se por simular as condições de dano através da introdução de massas à estrutura, fazendo-se com a mesma tenha suas frequências naturais alteradas de forma semelhante ao que ocorreria se houvesse a presença de dano.

A Tabela 2 e a Figura 12 relacionam a quantidade de massa utilizada em cada uma das barras horizontais com as respectivas classes de danos simuladas. Na Figura 12 também são mostradas as posições dos acelerômetros (ACEL).


Os dados advindos das respostas dinâmicas captadas pelos acelerômetros foram registrados por sistema de aquisição de dados da empresa Lynx, modelo ADS1800.

Tabela 2 – Distribuição de massas para cada tipo de estado estrutural

Classe de dano	Massa 1 (kg)	Massa 2 (kg)
1 - Sem dano	0	0
2 - Dano nível A	0,00781	0
3 - Dano nível B	0,01562	0
4 - Dano nível C	0,01562	0,00781
5 - Dano nível D	0,01562	0,01562

Fonte – Elaborado pelo autor, 2020

Figura 12 – Posições dos elementos do ensaio (mm)



Fonte – Elaborado pelo autor, 2020

Abaixo serão enumeradas as etapas de como foram realizados os ensaios do pórtico bi-engastado:

1. As massas são inseridas ou não nas suas respectivas posições, conforme a Tabela 2.
2. Iniciam-se os equipamentos que capturam os sinais.
3. O pêndulo é colocado na posição, conforme mostrado na Figura 12, e liberado do repouso, excitando a estrutura.
4. Os dados das respostas dinâmicas da estrutura são salvos pelo sistema de aquisição de sinais.

Os ensaios descritos pelas etapas acima foram repetidos por pelo menos trezentas vezes, para cada um dos estados de integridade estrutural simulados.

Foram realizados no total 1663 ensaios. Na Tabela 3 são detalhadas as quantidades de ensaios realizados para cada um dos cenários de dano.

Classe de dano	Quantidade de ensaios realizados
1 - Sem dano	383
2 - Dano nível A	324
3 - Dano nível B	319
4 - Dano nível C	320
5 - Dano nível D	317

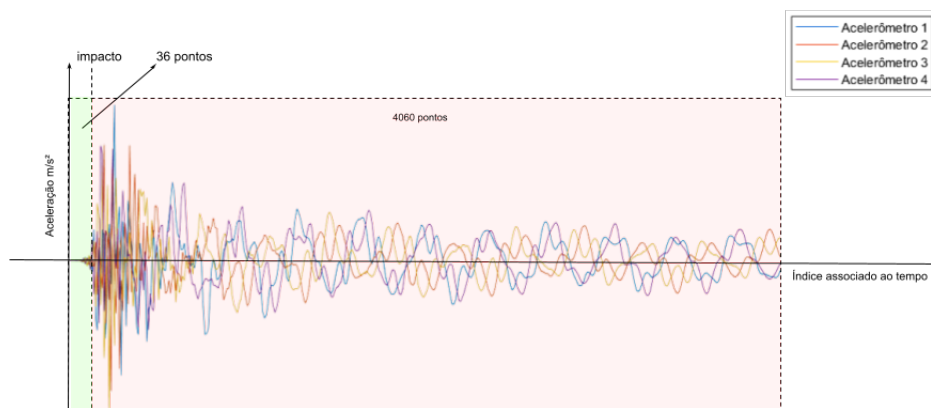
Tabela 3 – Quantidade de ensaios para cada cenário de dano

3.2 Tratamento dos dados

Neste trabalho foram considerados 1500 ensaios dos 1663 realizados, 300 para cada cenário de dano escolhidos aleatoriamente. Estes são representados computacionalmente por matrizes compostas pelas respostas dinâmicas da estrutura ao longo do tempo. As colunas desta matriz representam os sinais adquiridos pelos acelerômetros e as linhas os instantes de tempo, compondo séries temporais.

O primeiro tratamento de dados realizado foi a padronização de todas séries temporais, limitando a quantidade de elementos e determinando um ponto de início. Para isso, foram considerados 36 instantes de tempo (fundo verde-claro na Figura 13 que antecedem o impacto e 4060 durante e após o impacto (fundo vermelho-claro na Figura 13). Na Figura 13 é mostrado um exemplo (fora de escala) de como essas séries temporais foram tratadas. As linhas coloridas são as respostas dinâmicas captadas pelos acelerômetros, e o retângulo preto delimita o conjunto de elementos que foram considerados para aplicar os indicadores estatísticos.

Figura 13 – Exemplo gráfico do tratamento das séries temporais e dos elementos que foram considerados.



Fonte – Elaborado pelo autor, 2020

Após o tratamento acima, os dados dos ensaios são transformados em matrizes $\mathbf{M}_{4 \times 4096}$ (4 séries temporais, sendo uma para cada acelerômetro, contendo as respostas dinâmicas com 4096 acelerações discretizadas no tempo). A partir de cada Matriz \mathbf{M}

é possível extrair os respectivos indicadores estatísticos que servem de entrada para os algoritmos de classificação.

Visando avaliar a qualidade dos indicadores estatísticos apresentados nas equações 2.1 a 2.12, dois grupos de indicadores foram utilizados, estes serão descritos abaixo.

3.2.1 Grupo 1 de indicadores estatísticos

O Grupo 1 de indicadores refere-se aos 10 indicadores estatísticos de FARRAR e WORDEN (9), que são calculados através das equações 2.1 a 2.10. Como consequência, uma dada matriz $\mathbf{M}_{4 \times 4096}$ é reduzida para uma matriz com 4 pontos monitorados x 10 indicadores estatísticos. Visando simplificar a entrada de dados, os elementos desta última matriz foram condensados em um vetor com 40 posições. Estratégias semelhantes foram utilizadas nos trabalhos de AMARAL(2017) (3), ALVES et al. (10), LI et al. (11), MOUGHTY e CASAS (12) e DE LA ROSA (13).

3.2.2 Grupo 2 de indicadores estatísticos

O Grupo 2 de indicadores é formado por 5 indicadores, resultado da combinação de 3 indicadores sugeridos por FARRAR e WORDEN (9), descritos pelas equações 2.4, 2.5 e 2.10, com 2 utilizados no trabalho de MOUGHTY e CASAS (12), descritos pelas equações 2.11 e 2.12. A escolha destes indicadores foi feita através da observação dos bons resultados obtidos por MOUGHTY e CASAS (12) e de uma análise prévia de componentes principais, indicando que os 3 indicadores de FARRAR e WORDEN (9) usados no Grupo 2 são os que possuem maior peso para explicar a variância dos dados.

Este segundo grupo possui como principal vantagem gerar vetores de entrada menores, o que diminui significativamente o custo computacional para o treinamento e classificações. Dessa forma, uma entrada gerada a partir deste grupo terá 5 indicadores estatísticos para cada série temporal. Ou seja, uma matriz $\mathbf{M}_{4 \times 4096}$ se torna um vetor de entrada com 20 elementos.

3.3 Classificação dos dados

Nesta seção, os algoritmos de classificação serão avaliados para o conjunto de dados do pórtico bi-engastado. Estes serão treinados utilizando um conjunto de dados de entrada (séries de indicadores estatísticos). Após o treinamento, outro conjunto de dados testará a performance de cada método.

Para obter uma melhor avaliação dos erros de classificação obtidos, serão criados 40 modelos, partindo-se de dados de treinamento escolhidos aleatoriamente para cada grupo de indicadores. Os erros obtidos por cada modelo serão representados graficamente, junto

aos respectivos erro médio e desvio padrão do erro. Além disso, com intuito de comparar a eficiência dos modelos, serão apresentados também os tempos de execução.

3.3.1 Redes Neurais Artificiais

Para treinar cada modelo de ANN, o conjunto de dados foi dividido da seguinte forma: 35% para treinar o modelo, 15% para validações e 50% para os testes, totalizando, 210, 90 e 300 séries temporais, respectivamente. Ressalta-se que, apesar do percentual reduzido de dados de treinamento (35% dos dados), observou-se que 210 ensaios foram suficientes para um treinamento que levou a resultados de classificação satisfatórios, tendo como referência os resultados obtidos por AMARAL(2017) (3).

A quantidade de neurônios foi definida a partir da utilização de um algoritmo genético (AG), que indicou que uma ANN tende a ser mais bem-sucedida com 23 neurônios quando utilizado o Grupo 1 de indicadores e 5 neurônios utilizando o Grupo 2 de indicadores. Em ambos os casos foi adotado apenas uma camada oculta.

É importante destacar que para todos os resultados relacionados às classificações são sempre relativos aos dados de teste (300 ensaios obtidos a partir de uma amostragem aleatória para cada um dos 40 modelos = 12000 classificações).

Para permitir a visualização do desempenho das classificações pelas ANN, na Figura 14 é mostrada a matriz confusão consolidada das classificações obtidas através dos 40 modelos do Grupo 1 de indicadores. Das 12000 predições realizadas apenas 41 foram incorretas.


Figura 14 – Matriz confusão das classificações realizadas pelos modelos (ANN) utilizando o Grupo 1 de indicadores estatísticos

Classe predita	1	2313 19.3%	3 0.0%	3 0.0%	0 0.0%	0 0.0%	99.7% 0.3%
	2	4 0.0%	2385 19.9%	6 0.1%	0 0.0%	0 0.0%	99.6% 0.4%
	3	1 0.0%	7 0.1%	2354 19.6%	3 0.0%	0 0.0%	99.5% 0.5%
	4	0 0.0%	11 0.1%	1 0.0%	2448 20.4%	0 0.0%	99.5% 0.5%
	5	0 0.0%	2 0.0%	0 0.0%	0 0.0%	2459 20.5%	99.9% 0.1%
			99.8% 0.2%	99.0% 1.0%	99.6% 0.4%	99.9% 0.1%	100% 0.0%
		1	2	3	4	5	
		Classe esperada					

Fonte – Elaborado pelo autor, 2022

A Figura 15 mostra os erros obtidos por cada modelo de ANN utilizando o Grupo 1 de indicadores. O erro médio obtido foi de aproximadamente 0,3% e o desvio padrão igual a 0,436 %.


Figura 15 – Gráfico do erro por modelo (ANN) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Na Figura 16 é mostrado o tempo de execução para cada modelo e o tempo médio obtido com classificações por ANN utilizando o Grupo 1 de indicadores. O tempo médio para execução de cada modelos foi de aproximadamente 1,9 segundos.

Figura 16 – Gráfico de tempo de execução por modelo (ANN) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

A Figura 17 mostra a matriz confusão gerada através de todas as classificações, utilizando o Grupo 2 de indicadores, realizadas pelos 40 modelos. Em 12000 classificações apenas 243 foram equivocadas.

Na Figura 18 são mostrados os erros obtidos pelos modelos utilizando o Grupo 2 de indicadores. O erro médio foi de aproximadamente 2,3% e o desvio padrão igual a 1,09%.


Já na Figura 19, observa-se que o tempo médio de execução dos modelos foi de aproximadamente 0,40 segundos, utilizando o Grupo 2 de indicadores.

Figura 17 – Matriz confusão das classificações realizadas pelos modelos (ANN) utilizando o Grupo 2 de indicadores estatísticos

Classe predita	1	2497 20.8%	5 0.0%	5 0.0%	0 0.0%	2 0.0%	99.5% 0.5%
	2	17 0.1%	2312 19.3%	3 0.0%	16 0.1%	7 0.1%	98.2% 1.8%
	3	0 0.0%	2 0.0%	2231 18.6%	40 0.3%	0 0.0%	98.2% 1.8%
	4	0 0.0%	44 0.4%	43 0.4%	2335 19.5%	4 0.0%	96.2% 3.8%
	5	18 0.1%	61 0.5%	1 0.0%	3 0.0%	2354 19.6%	96.6% 3.4%
		98.6% 1.4%	95.4% 4.6%	97.7% 2.3%	97.5% 2.5%	99.5% 0.5%	97.7% 2.3%
	1	2	3	4	5		
	Classe esperada						


Fonte – Elaborado pelo autor, 2022

Figura 18 – Gráfico do erro por modelo (ANN) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Figura 19 – Gráfico de tempo de execução por modelo (ANN) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Comparando os resultados obtidos através do uso do Grupo 2 de indicadores com os do Grupo 1, observa-se que o erro obtido foi aproximadamente 7,33 vezes maior e o tempo de execução 2,9 vezes menor.

3.3.2 Máquinas de vetores suporte

O algoritmo SVM adotado utiliza como kernel a função linear com a estratégia um-contra-um, que constrói um classificador para cada par de classe, e o parâmetro C igual a 1. Para o treinamento foi usado um conjunto de 210 amostras e, para teste, um conjunto com 300 amostras. Os resultados que seguem são apresentados para os 300 amostras de teste aplicados aos 40 modelos, resultando em 12000 classificações.

Os 40 modelos de SVM, utilizando o Grupo 1 de indicadores, realizaram 12000 classificações, onde apenas 62 destas foram predições incorretas, conforme mostrado na Figura 20.

Figura 20 – Matriz confusão das classificações realizadas pelos modelos (SVM) utilizando o Grupo 1 de indicadores estatísticos

1	2382 19.9%	0 0.0%	8 0.1%	0 0.0%	0 0.0%	99.7% 0.3%
2	19 0.2%	2364 19.7%	1 0.0%	2 0.0%	0 0.0%	99.1% 0.9%
3	0 0.0%	4 0.0%	2386 19.9%	0 0.0%	0 0.0%	99.8% 0.2%
4	0 0.0%	19 0.2%	0 0.0%	2387 19.9%	7 0.1%	98.9% 1.1%
5	0 0.0%	2 0.0%	0 0.0%	0 0.0%	2419 20.2%	99.9% 0.1%
	99.2% 0.8%	99.0% 1.0%	99.6% 0.4%	99.9% 0.1%	99.7% 0.3%	99.5% 0.5%
	1	2	3	4	5	
	Classe esperada					


Fonte – Elaborado pelo autor, 2022

Na Figura 21 são mostrados todos os erros obtidos por cada modelo de SVM através do Grupo 1 de indicadores. O erro médio dos modelos foi de aproximadamente 0,5% e o desvio padrão igual a 0,446%.

Já na Figura 22 são exibidos os tempos de execução para todos os 40 modelos de SVM utilizando o Grupo 1 de indicadores. O tempo médio de execução foi de aproximadamente 0,20 segundos.


Na Figura 23 mostra as classificações realizadas por todos os 40 modelos de SVM utilizando o Grupo 2 de indicadores. De 12000 predições realizadas 384 foram incorretas.

Figura 21 – Gráfico do erro por modelo (SVM) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Figura 22 – Gráfico de tempo de execução por modelo (SVM) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022


Figura 23 – Matriz confusão das classificações realizadas pelos modelos (SVM) utilizando o Grupo 2 de indicadores estatísticos

Classe predita	1	2302 19.2%	9 0.1%	6 0.1%	0 0.0%	0 0.0%	99.4% 0.6%
	2	45 0.4%	2248 18.7%	0 0.0%	31 0.3%	0 0.0%	96.7% 3.3%
	3	0 0.0%	0 0.0%	2318 19.3%	19 0.2%	0 0.0%	99.2% 0.8%
	4	0 0.0%	85 0.7%	68 0.6%	2358 19.7%	11 0.1%	93.5% 6.5%
	5	81 0.7%	29 0.2%	0 0.0%	0 0.0%	2390 19.9%	95.6% 4.4%
			94.8% 5.2%	94.8% 5.2%	96.9% 3.1%	97.9% 2.1%	99.5% 0.5%
		Classe esperada					

Fonte – Elaborado pelo autor, 2022

Na Figura 24 são mostrados os erros obtidos pelos modelos de SVM utilizando o Grupo 2 de indicadores. O erro médio é de aproximadamente 3,2% e o desvio padrão 1,034% , conforme mostrado na Figura


Figura 24 – Gráfico do erro por modelo (SVM) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Já o tempo médio de execução dos modelos, utilizando o Grupo 2 de indicadores, foi de aproximadamente 0,23 segundos, conforme é mostrado na Figura 25.

Figura 25 – Gráfico de tempo de execução por modelo (SVM) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Comparando os resultados das classificações realizadas através de SVM para os dois grupos de indicadores, foram obtidos tempos de execução similares, mas o Grupo 2 foi mais eficaz nas classificações.

3.3.3 K-vizinhos mais próximos

Para as classificações foi utilizada o algoritmo *fine K nearest neighbor* (28), que é uma das variações do método KNN, que se demonstrou eficaz para indicar danos estruturais no trabalho de VITOLA et al. (29). Para o treinamento foi usado um conjunto de 210 amostras e, para teste, um conjunto com 300 amostras. Os resultados que seguem são

apresentados para os 300 amostras de teste aplicados aos 40 modelos, resultando em 12000 classificações.

A Figura 26 consolida todas as classificações obtidos pelos 40 modelos de KNN utilizando o Grupo 1 de indicadores. Das 12000 predições realizadas apenas 125 foram incorretas.


Figura 26 – Matriz confusão das classificações realizadas pelos modelos (KNN) utilizando o Grupo 1 de indicadores estatísticos

Classe predita	1	2389 19.9%	1 0.0%	5 0.0%	0 0.0%	0 0.0%	99.7% 0.3%
	2	20 0.2%	2344 19.5%	12 0.1%	3 0.0%	0 0.0%	98.5% 1.5%
	3	0 0.0%	6 0.1%	2327 19.4%	11 0.1%	0 0.0%	99.3% 0.7%
	4	0 0.0%	24 0.2%	16 0.1%	2389 19.9%	12 0.1%	97.9% 2.1%
	5	8 0.1%	4 0.0%	0 0.0%	3 0.0%	2426 20.2%	99.4% 0.6%
		98.8% 1.2%	98.5% 1.5%	98.6% 1.4%	99.3% 0.7%	99.5% 0.5%	99.0% 1.0%
	1	2	3	4	5		
	Classe esperada						

Fonte – Elaborado pelo autor, 2022

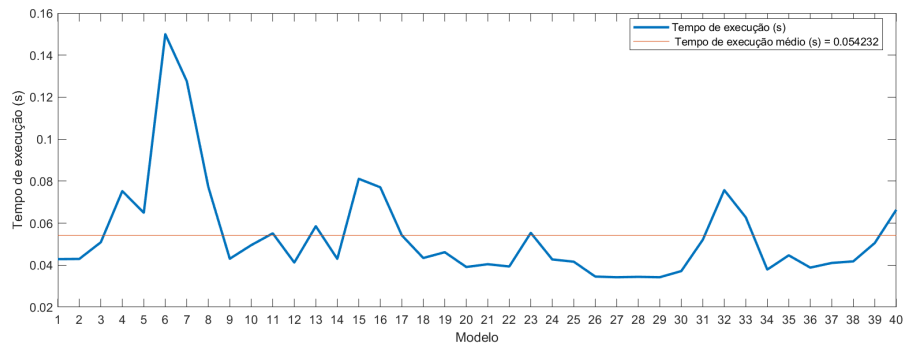
Na Figura 27 e na Figura 28 são mostrados, respectivamente, os erros obtidos e os tempos de execução para cada modelo de KNN utilizando o Grupo 1 de indicadores. O erro médio é de aproximadamente 1,04%, com desvio padrão igual a 0,6588% e o tempo médio de execução é igual a 0,05 segundos.

Figura 27 – Gráfico do erro por modelo (KNN) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Figura 28 – Gráfico de tempo de execução por modelo (KNN) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

A matriz confusão apresentada na Figura 29 traz a consolidação de todas as classificações realizadas pelos 40 modelos de KNN utilizando o Grupo 2 de indicadores. De 12000 predições realizadas 449 foram incorretas.

Figura 29 – Matriz confusão das classificações realizadas pelos modelos (KNN) utilizando o Grupo 2 de indicadores estatísticos


Classe predita	1	2353 19.6%	10 0.1%	4 0.0%	0 0.0%	0 0.0%	99.4% 0.6%
	2	20 0.2%	2207 18.4%	7 0.1%	51 0.4%	9 0.1%	96.2% 3.8%
	3	0 0.0%	1 0.0%	2320 19.3%	48 0.4%	1 0.0%	97.9% 2.1%
	4	0 0.0%	65 0.5%	93 0.8%	2294 19.1%	44 0.4%	91.9% 8.1%
	5	32 0.3%	46 0.4%	0 0.0%	18 0.1%	2377 19.8%	96.1% 3.9%
		97.8% 2.2%	94.8% 5.2%	95.7% 4.3%	95.1% 4.9%	97.8% 2.2%	96.3% 3.7%
	Classe esperada						

Fonte – Elaborado pelo autor, 2022

Na Figura 30 é mostrada a taxa de erro para cada modelo de KNN utilizando o Grupo 2 de indicadores. O erro médio obtido foi de aproximadamente 3,74% e o desvio padrão igual a 0,976%.


Na Figura 31 são exibidos os tempos de execução para cada modelo de KNN utilizando o Grupo 2 de indicadores. O tempo médio de execução foi de aproximadamente 0,03 segundos.

Figura 30 – Gráfico do erro por modelo (KNN) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Figura 31 – Gráfico de tempo de execução por modelo(KNN) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Comparando os modelos dos dois grupos de indicadores para as classificações utilizando KNN, o Grupo 1 foi mais bem-sucedido nas classificações, e o Grupo 2 obteve um tempo médio de execução menor.

3.3.4 Comparação dos modelos

A Tabela 4 lista os erros médios das classificações, desvios-padrão dos erros e os tempos médios de execução para os modelos de ANN, SVM e KNN, utilizando o Grupo 1 e o Grupo 2 de indicadores estatísticos. No geral, todos os métodos que utilizaram o Grupo 1 de indicadores foram mais eficientes do que os respectivos do Grupo 2, durante as classificações. O método mais eficaz foi a ANN utilizando o Grupo 1 de indicadores. Entretanto, esta estratégia obteve o maior tempo de execução médio. Por outro lado, o método com a maior taxa de erro médio foi o KNN utilizando o Grupo 2 indicadores. Os métodos que utilizaram o Grupo 1 de indicadores tiveram, em média, desvios-padrão menores, o que pode indicar que estes resultados são mais confiáveis. Com relação aos tempos de execução, observou-se que a ANN e KNN forneceram valores menores para o Grupo 2,

fato que não ocorreu no caso das SVM, onde o tempo médio obtido pelo Grupo 1 foi melhor.

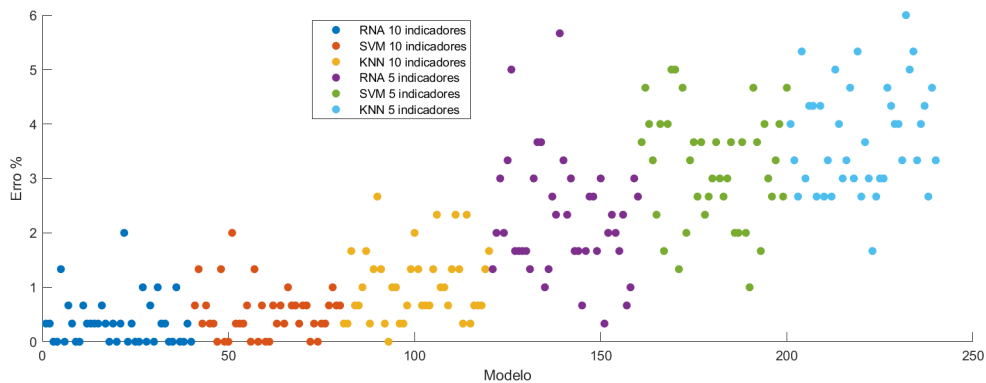
Tabela 4 – Tabela dos resultados médios obtidos através das classificações

Indicadores	Grupo 1			Grupo 2		
Método	ANN	SVM	KNN	ANN	SVM	KNN
Tempo de Execução médio (s)	1,8968	0,2024	0,0542	0,4052	0,2374	0,0300
Erro médio (%)	0,34	0,52	1,4	2,26	3,2	3,74
Desvio Padrão (%)	0,44	0,45	0,66	1,10	1,03	0,98

Fonte – Elaborado pelo autor, 2022

Na Figura 32 são mostrados os erros de todos os 240 modelos gerados durante as aplicações de cada um dos métodos e grupos de indicadores. É possível observar que todos os algoritmos utilizando o Grupo 1 obtiveram menores erros quando comparados com seus respectivos resultados alcançados pelo Grupo 2.

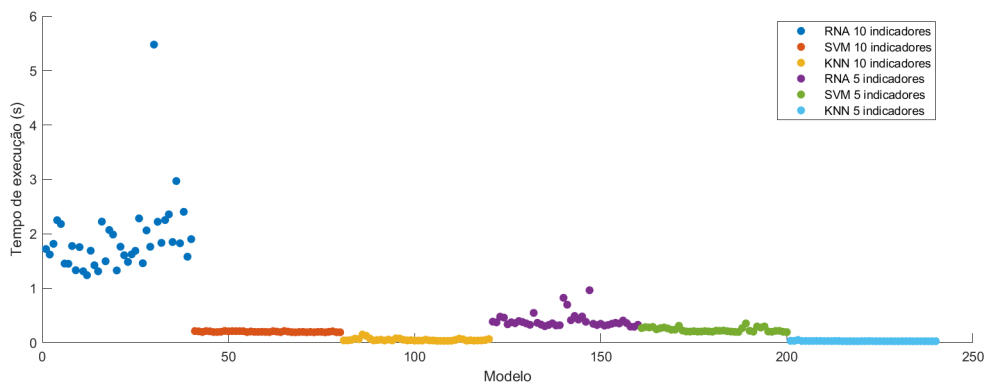
Figura 32 – Gráfico do erro obtido pelos 240 modelos dos algoritmos aplicados.



Fonte – Elaborado pelo autor, 2022

Já na Figura 33 são mostrados os tempos de execução para todos os modelos gerados para cada um dos métodos utilizados. Conforme foi previsto, o KNN obteve um menor tempo de execução que os demais métodos.

Figura 33 – Gráfico do tempo obtido pelos 240 modelos dos algoritmos aplicados.



Fonte – Elaborado pelo autor, 2022

4 Ponte Z24

A ponte Z-24 foi construída entre os anos de 1961 e 1963, e estava localizada entre as cidades de Berna e Zurique. Essa ponte foi substituída por outra (ponte A36) e antes de sua demolição foram feitos vários ensaios dinâmicos (30), inclusive ensaios com danos provocados na estrutura. Segundo MAECK (31), os experimentos foram realizados através de um projeto chamado SIMCES (*System Identification to Monitor Civil Engineering*). De acordo com BARBOSA e CREMONA (30), foram utilizados 154 acelerômetros, posicionados pela estrutura, e houve dois tipos de excitações na estrutura: Excitação ambiente e excitações impostas por excitadores de forma aleatória.

Figura 34 – Fotografia da ponte Z24




Fonte – BARBOSA e CREMONA (30)

4.1 Aquisição dos Sinais

A estrutura foi gradualmente danificada e, com o auxílio de um macaco hidráulico instalado no pilar indicado na Figura 35, foram simuladas três condições de integridade estrutural para a ponte Z24. Outros cenários de danos não foram considerados neste trabalho.

Os estados de integridade estruturais analisados foram denominados de: 1 - sem dano (estrutura íntegra); 2 - dano nível A (estrutura após a inserção de um recalque de 40mm no pilar indicado na Figura 35); 3 - dano nível B (estrutura após a retirada do recalque). Para cada cenário foram captados os sinais dinâmicos da estrutura com um frequência de aquisição de 100Hz. Cada ensaio resultou em uma matriz $\mathbf{M}_{65535 \times 5}$, composta

Figura 35 – Corte transversal da ponte Z24



Fonte – Adaptado de AMARAL(2020) (32)

por séries temporais com 65535 elementos para cada um dos 5 pontos instrumentados considerados neste trabalho. Foram realizados 9 ensaios para cada cenário avaliado.

4.2 Tratamento de dados

Os Grupos de indicadores estatísticos 1 e 2 foram calculados para trechos de 600 séries temporais registradas nas 9 matrizes \mathbf{M} e para cada cenário avaliado. Estes trechos foram selecionados aleatoriamente das matrizes \mathbf{M} e possuem amostras com 3 segundos de instrumentação (300 pontos).

4.3 Classificação de dados

De forma análoga à apresentada no exemplo anterior, 40 modelos obtidos de forma aleatória são gerados para a avaliação do erros de classificação e respectivos tempos de processamento.

4.3.1 Redes Neurais Artificiais

Assim como foi feito para o pórtico, para treinar cada modelo de ANN, o conjunto de amostras foi dividido da seguinte forma: 35% para treinar o modelo, 15% para validações e 50% para os testes, totalizando, 210, 90 e 300 séries temporais, respectivamente. A quantidade de neurônios foi definida a partir da utilização de um algoritmo genético (AG), que indicou que uma ANN tende a ser mais bem-sucedida com 26 neurônios quando utilizado o Grupo 1 de indicadores e 13 neurônios utilizando o Grupo 2 de indicadores.

Os resultados foram obtidos através das amostras de teste dos 40 modelos de ANN.

Na Figura 36 é mostrada a matriz confusão consolidada das classificações obtidas através dos 40 modelos considerando o do Grupo 1 de indicadores. Das 12000 predições realizadas 1207 foram incorretas.


A Figura 37 mostra os erros obtidos por cada modelo de ANN utilizando o Grupo 1 de indicadores. O erro médio obtido foi de aproximadamente 10,06% e o desvio padrão igual a 2,77 %.

Figura 36 – Matriz confusão das classificações realizadas pelos modelos (ANN) utilizando o Grupo 1 de indicadores estatísticos

Classe predita	1	3770 31.4%	160 1.3%	3 0.0%	95.9% 4.1%
	2	230 1.9%	3348 27.9%	383 3.2%	84.5% 15.5%
	3	10 0.1%	421 3.5%	3675 30.6%	89.5% 10.5%
		94.0% 6.0%	85.2% 14.8%	90.5% 9.5%	89.9% 10.1%
		Classe esperada			
		1	2	3	

Fonte – Elaborado pelo autor, 2022

Figura 37 – Gráfico do erro por modelo (ANN) utilizando o Grupo 1 de indicadores estatísticos




Fonte – Elaborado pelo autor, 2022

Na Figura 38 é mostrado o tempo de execução para as classificações com ANN utilizando o Grupo 1 de indicadores. O tempo médio obtido foi de aproximadamente 5,7 segundos.

A Figura 39 mostra a matriz confusão gerada através de todas as classificações realizadas pelos 40 modelos utilizando o Grupo 2 de indicadores. Em 12000 classificações, 870 foram equivocadas.

Figura 38 – Gráfico de tempo de execução por modelo (ANN) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Figura 39 – Matriz confusão das classificações realizadas pelos modelos (ANN) utilizando o Grupo 2 de indicadores estatísticos

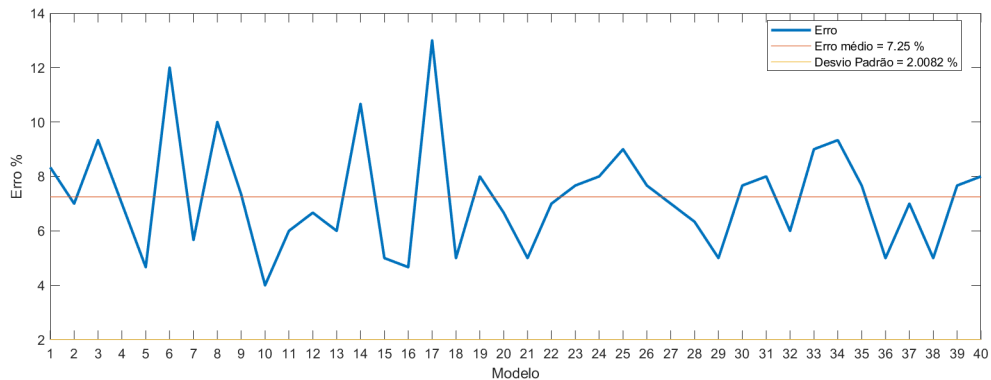
Classe predita	1	3757 31.3%	187 1.6%	1 0.0%	95.2% 4.8%
	2	180 1.5%	3512 29.3%	264 2.2%	88.8% 11.2%
	3	0 0.0%	238 2.0%	3861 32.2%	94.2% 5.8%
		95.4% 4.6%	89.2% 10.8%	93.6% 6.4%	92.8% 7.3%
	Classe esperada				

Fonte – Elaborado pelo autor, 2022

Na Figura 40 são exibidos os erros relativos aos 40 modelos de ANN utilizando o Grupo 2 de indicadores. O erro médio foi de 7,25% e desvio padrão igual a 2,00 %.


Na Figura 41 são mostrados os tempos de execução obtidos pelos 40 modelos de ANN utilizando o Grupo 2 de indicadores. O tempo médio de execução foi de aproximadamente 1,05 segundos.

Figura 40 – Gráfico do erro por modelo (ANN) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Figura 41 – Gráfico de tempo de execução por modelo (ANN) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022


Comparando os resultados dos dois grupos, o Grupo 2 foi 1,38 vezes mais eficiente nas classificações e obteve um tempo médio de execução 5,46 vezes menor do que o Grupo 1.

4.3.2 Máquinas de vetores suporte

Os modelos SVM foram obtidos considerando-se os mesmos quantitativos de sinais usados para as ANN, ou seja: 210 sinais para treino e 300 sinais para teste. Os resultados que seguem, assim como para ANN, são relativos às classificações dos dados de teste.

Os 40 modelos de SVM, utilizando o Grupo 1 de indicadores, realizaram 12000 classificações, 849 destas foram predições incorretas, conforme mostrado na Figura 42.


Figura 42 – Matriz confusão das classificações realizadas pelos modelos (SVM) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Na Figura 43 são mostrados todos os erros obtidos pelos 40 modelos de SVM utilizando o Grupo 1 de indicadores. O erro médio foi de aproximadamente 7,07% e o desvio padrão igual a 1,977%.


Figura 43 – Gráfico do erro por modelo (SVM) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Já na Figura 44 são exibidos os tempos de execução para todos os 40 modelos de SVM utilizando o Grupo 1 de indicadores. O tempo médio de execução foi de aproximadamente 1,01 segundos.


Figura 44 – Gráfico de tempo de execução por modelo (SVM) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Na Figura 45 mostra as classificações realizadas por todos os 40 modelos de SVM utilizando o Grupo 2 de indicadores. De 12000 predições realizadas 786 foram incorretas.

Figura 45 – Matriz confusão das classificações realizadas pelos modelos (SVM) utilizando o Grupo 2 de indicadores estatísticos




Fonte – Elaborado pelo autor, 2022

Na Figura 46 são exibidos os erros dos 40 modelos de SVM utilizando o Grupo 2 de indicadores. O erro médio é de aproximadamente 6,55% e o desvio padrão 1,6392% , conforme mostrado

Já o tempo médio de execução dos modelos, utilizando o Grupo 2 de indicadores,


Figura 46 – Gráfico do erro por modelo (SVM) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

foi de aproximadamente 0,20 segundos, conforme é mostrado na Figura 47.

Figura 47 – Gráfico de tempo de execução por modelo(SVM) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Comparando-se os resultados obtidos para os Grupos 1 e 2, observa-se que os tempos menores e as melhores taxas de erros foram obtidos para o grupo com menos indicadores.

4.3.3 K-vizinhos mais próximos

Assim como no exemplo da aplicação anterior, para as classificações através do algoritmo KNN foi utilizada a variação *fine K nearest neighbor*.

A Figura 48 consolida todas as classificações obtidos pelos 40 modelos do método KNN utilizando o Grupo 1 de indicadores, mostrando que das 12000 predições realizadas, 1610 foram incorretas.


Figura 48 – Matriz confusão das classificações realizadas pelos modelos (KNN) utilizando o Grupo 1 de indicadores estatísticos

Classe predita	1	3719 31.0%	128 1.1%	0 0.0%	96.7% 3.3%
	2	204 1.7%	3174 26.5%	534 4.5%	81.1% 18.9%
	3	4 0.0%	740 6.2%	3497 29.1%	82.5% 17.5%
		94.7% 5.3%	78.5% 21.5%	86.8% 13.2%	86.6% 13.4%
		Classe esperada			
		1	2	3	

Fonte – Elaborado pelo autor, 2022

Na Figura 49 são exibidos os erros obtidos pelos 40 modelos de KNN para o Grupo 1. O erro médio é de aproximadamente 13,41% e o desvio padrão é igual a 2,4105%.


Figura 49 – Gráfico do erro por modelo (KNN) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Já na Figura 50 são mostrados os tempos de execução dos modelos de KNN para o Grupo 1. O tempo médio de execução é igual a 0,96 segundos.


Figura 50 – Gráfico de tempo de execução por modelo (KNN) utilizando o Grupo 1 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

A matriz confusão apresentada na Figura 51 traz a consolidação de todas as classificações realizadas pelos 40 modelos de KNN utilizando o Grupo 2 de indicadores. De 12000 predições realizadas, 1224 foram incorretas.

Figura 51 – Matriz confusão das classificações realizadas pelos modelos (KNN) utilizando o Grupo 2 de indicadores estatísticos




Fonte – Elaborado pelo autor, 2022

Na Figura 52 são mostrados os erros dos 40 modelo de KNN utilizando o Grupo 2 de indicadores. O erro médio obtido foi de aproximadamente 9,37% e o desvio padrão é

igual a 2,4885%.


Figura 52 – Gráfico do erro por modelo (KNN) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Na Figura 53 são exibidos os tempos de execução para cada modelo de KNN utilizando o Grupo 2 de indicadores. O tempo médio de execução foi de 0,15 segundos.

Figura 53 – Gráfico de tempo de execução por modelo (KNN) utilizando o Grupo 2 de indicadores estatísticos



Fonte – Elaborado pelo autor, 2022

Comparando os modelos dos dois grupos de indicadores para as classificações utilizando KNN, os modelos que utilizaram o Grupo 2 de indicadores foram mais rápidos e eficazes nas classificações.

4.3.4 Comparação dos modelos

A Tabela 5 lista os erros médios, desvios-padrão e os tempos médios de execução para os modelos de ANN, SVM e KNN utilizando os dois grupos de indicadores estatísticos. No geral, todos os métodos que utilizaram o Grupo 2 de indicadores, além de

terem alcançado uma melhor taxa de classificações corretas, tiveram menores tempos de processamento. O método mais eficaz foi a SVM utilizando o Grupo 2 de indicadores e o método com a maior taxa de erro médio foi o KNN utilizando o Grupo 1 indicadores. Conforme era esperado, os algoritmos que utilizaram o Grupo 2 de indicadores foram executados mais rápidos, já que conjuntos de dados menores tendem a demandar menos tempo de processamento. O menor desvio padrão médio observado foi para as SVM do Grupo 2 de indicadores.


Tabela 5 – Tabela dos resultados médios obtidos através das classificações

Indicadores	Grupo 1			Grupo 2		
	ANN	SVM	KNN	ANN	SVM	KNN
Método						
Tempo de Execução médio (s)	5,7504	1,0184	0,9619	1,0530	0,2019	0,1583
Erro médio (%)	10,05	7,08	13,42	7,25	6,55	9,37
Desvio Padrão (%)	2,77	1,98	2,41	2,0082	1,64	2,49

Fonte – Elaborado pelo autor, 2022

Na Figura 54 são mostradas no gráfico os erros de todos os 240 modelos gerados durante as aplicações de cada um dos métodos e grupos de indicadores. É possível observar os algoritmos que utilizaram o Grupo 2 de indicadores tiveram taxas de erros ligeiramente menores quando comparados com os respectivos resultados para o Grupo 1.


Figura 54 – Gráfico do erro obtido pelos 240 modelos dos algoritmos aplicados.



Fonte – Elaborado pelo autor, 2022

Já na Figura 55 são mostrados os tempos de execução dos 240 modelos gerados. Conforme foi previsto, os modelos que utilizaram o Grupo 2 de indicadores foram executados mais rapidamente. Além disso, o método KNN foi mais rápido que os demais para ambos os grupos. A ANN utilizando o Grupo 1 de indicadores foi o algoritmo mais computacionalmente custoso desta aplicação.

Figura 55 – Gráfico do tempo obtido pelos 240 modelos dos algoritmos aplicados.



Fonte – Elaborado pelo autor, 2022

5 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho teve como foco avaliar o uso de Redes Neurais Artificiais, Maquinas de Vetor Suporte e K-Vizinhos Mais Proximos em problemas de classificação de danos estruturais. Dois Grupos de indicadores estatísticos foram usados como dados de entrada dos algoritmos de IA: Grupo 1: um conjunto de 10 parâmetros (já usados em outros trabalhos da literatura e propostos por FARRAR e WORDEN(9)) e Grupo 2: um conjunto de 5 parâmetros (escolhidos pelo autor e contendo 3 parâmetros do Grupo 1 e dois parâmetros propostos por MOUGHTY e CASAS (12)).

Duas aplicações foram analisadas visando evidenciar as vantagens e desvantagens de cada algoritmo de IA avaliado, bem como a qualidade dos dados de entrada definidos pelos Grupos 1 e 2.

A primeira aplicação foi um pórtico constituído de barras esbeltas ensaiado pelo autor no LIS/UFJF. Para este caso, observou-se que todos os métodos de IA avaliados alcançaram melhores taxas de classificação para dados de entrada provenientes do Grupo 1. As ANN foram as que alcançaram as melhores taxas de classificações corretas, seguidas pelas SVM e KNN, nesta ordem. Este resultado difere ligeiramente daqueles obtidos por AMARAL(2017) (3), que obteve resultados um pouco melhores através do uso de SVM, quando comparados com ANN (lembrando que AMARAL não avaliou KNN). Esta pequena divergência de resultados pode ser explicada pelo uso de um algoritmo genético para otimizar os parâmetros da ANN no presente trabalho, algo que não foi realizado para os parâmetros do SVM. Entretanto, observa-se que, tanto nos resultados aqui alcançados, quanto naqueles apresentados por AMARAL, os desempenhos de ANN e SVM são relativamente próximos entre si. A comparação numérica direta entre as taxas de classificação dos dois trabalhos não foi apresentada uma vez que, em se tratando de exemplos distintos, fica difícil definir um critério objetivo de comparação. Apesar de um desempenho inferior, o KNN também apresentou baixos erros de classificação, tendo a vantagem de demandar um menor tempo de processamento.

A segunda aplicação foi o exemplo clássico da Ponte Z24 na Suíça. Neste caso ocorreu um comportamento diferente àquele observado no exemplo 1: o Grupo 2 apresentou melhores taxas de classificação corretas para todos os métodos de IA avaliados. Este fato pode estar relacionado a um número reduzido de amostras para a fase de treinamento, o que pode levar a modelos de classificação menos precisos quando se considera 10 indicadores estatísticos como dados de entrada, resultando em taxas de classificação corretas inferiores àquelas alcançadas nas suas respectivas análises do exemplo precedente. Mesmo diante desta possível ressalva, pode-se afirmar que os resultados obtidos neste exemplo sinalizam que quantidade não implica em qualidade, em termos de classificações corretas. Observa-se também para este exemplo que os melhores desempenhos dos algoritmos de IA em termo

de menores erros de classificações seguiu um ranqueamento diferente daquele alcançado no exemplo do pórtico, porém semelhante àquele obtido por AMARAL(2017) (3): melhores resultados para SVM, ANN e KNN, nesta ordem. Mais uma vez, o algoritmo KNN teve os menores tempos de processamentos, com taxas de classificações corretas inferiores às outras duas metodologias avaliadas.

Fazendo-se uma avaliação geral sobre os grupos de indicadores estatísticos usados, nota-se que é possível obter bons resultados em termos de classificações corretas com o Grupo de indicadores sugerido pelo autor.

Com relação aos algoritmos de IA testados, destaca-se que todos obtiveram taxas médias de classificação corretas relativamente elevadas, com tempos de processamento que não são empecilhos para suas respectivas aplicações. Estes resultados permitem afirmar que ANN, SVM e KNN podem se apresentar como possíveis classificadores em problemas associados a danos em estruturas. Entretanto os dois primeiros são mais recomendados por apresentarem desempenhos semelhantes entre si e superiores aos de KNN.

Através das considerações anteriores, pode-se recomendar para trabalhos futuros:

- Testar e buscar novos grupos de indicadores estatísticos;
- aplicar técnicas para otimização de parâmetros dos algoritmos de classificação; e
- verificar os desempenhos das metodologias apresentadas em outras estruturas.

REFERÊNCIAS

- 1 UFES, Universidade Federal do Espírito Santo, **Comunidades ainda sofrem efeitos da tragédia de Mariana e precisam de reparação, revela pesquisa**, Disponível em: <https://www.ufes.br/conteudo/comunidades-ainda-sofrem-efeitos-da-tragedia-de-mariana-e-precisam-de-reparacao-revela>. Acesso em: 19 de janeiro de 2021
- 2 G1, **Barragem da Vale se rompe em Brumadinho, MG**, Disponível em: <https://g1.globo.com/mg/minas-gerais/noticia/2019/01/25/bombeiros-e-de-fesa-civil-sao-mobilizados-para-chamada-de-rompimento-de-barragem-em-brumadinho-na-grande-bh.ghtml>. Acesso em: 19 de janeiro de 2021
- 3 AMARAL, Rafaelle Piazzaroli Finotti. **Aplicação de métodos computacionais a dados vibracionais para detecção de alterações estruturais**. 2017. Tese (Dissertação mestrado acadêmico) - Universidade Federal de Juiz de Fora, ICE/Engenharia. Programa de Pós-Graduação em Modelagem Computacional, 2017.
- 4 ALLEMANG,R.,**The modal assurance criterion-twenty years of use and abuse**, Sound and Vibration, v.37,n.8,pp.14-23,2003.
- 5 CURY, A., BORGES, C., BARBOSA, F., **A two-step technique for damage assessment using numerical and experimental vibration data**, Structural Health Monitoring, v. 10, n. 4, pp. 417–428, 2011.
- 6 PANDEY,A.,BISWAS,M.,**Damage detection in structures using changes in flexibility**, Journal of Sound and Vibration, v.169,n.1,pp.3-17,1994.
- 7 CURY, A., *Techniques d'anormalité appliquées à la surveillance des antéstructurale*, Ph.D. Thesis, Université Paris-Est, 2010.
- 8 IWASAKI, A., TODOROKI, A., SHIMAMURA, Y., KOBAYASHI, H., **An unsupervised statistical damage detection method for structural health 64 monitoring (applied to detection of delamination of a composite beam)**, Smart materials and structures, v. 13, n. 5, pp. N80, 2004
- 9 FARRAR, C.,WORDEN,K., **Structural health monitoring: a machine learning perspective**. John Wiley & Sons, 2012.
- 10 ALVES, V., CURY, A., ROITMAN, N., MAGLUTA, C., C., C., **Structural modification assessment using supervised learning methods applied to vibration data**, Engineering Structures, v. 99, pp. 439–448, 2015.
- 11 LI, F.; MENG, G.; YE, L.; CHEN, P. **Wavelet transform-based higher-order statistic for fault diagnosis in rolling elemento bearings**. Journal of Vibration and Control, v. 14, n. 11, p. 1691-1709, 2008.
- 12 MOUGHTY J. and Casas, J., 2017. **Damage sensitivity evaluation of vibration parameters under ambient excitation**.doi:10.1007/978-3-319-67443-8_21. 2
- 13 DE LA ROSA, J.; AGUERA-PÉREZ, A.; PALOMARES-SALAS, J.; MORENO-MUÑOZ, A. **Higher-order statistics: Discussion and interpretation**, 2013 Measurement, v. 46, n. 8, p. 2816-2827, 2013.

- 14 BALAGEAS, Daniel; FRITZEN, Claus-Peter; GÜEMES, Alfredo (Ed.). **Structural health monitoring**. John Wiley & Sons, 2010.
- 15 FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. S. **An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements**. Latin American Journal of Solids and Structures, v. 16, n. 2, e165, 2019.
- 16 EVGENIOU, Theodoros; PONTIL, Massimiliano.(2001). **Support Vector Machines: Theory and Applications**. 2049. 249-257. 10.1007/3-540-44673-7_12.
- 17 KOTHARI S.C.; , HEEKUCK Oh. (1993). **Neural Networks for Pattern Recognition**. [https://doi.org/10.1016/S0065-2458\(08\)60404-0](https://doi.org/10.1016/S0065-2458(08)60404-0).
- 18 CUNNINGHAM, Pdraig DELANY, Sarah. (2007). **k-Nearest neighbour classifiers** . Mult Classif Syst. 54. 10.1145/3459665.
- 19 SHAH, Hardik **A Full Overview of Artificial Neural Networks (ANN)**. 2020. learn.g2.com , Consultado em 31 de Dezembro de 2021
- 20 HAGAN, M. T.; MENHAJ, B. **Training Feedforward Networks with the Marquardt Algorithm**. IEEE transactions on Neural Networks, v. 5, n. 6, p. 989-993, 1994.
- 21 ALVANDI,A.,CREMONA,C., **Assessment of vibration-based damage identification techniques**, Journal of Sound and Vibration, v.292,n.1, pp. 179-202,2006.
- 22 FAN,W.,QIAO,P.,**Vibration-based damage identification methods: a review and comparative study**, Structural Health Monitoring, v.10,n.1, pp.83-111,2011.
- 23 NUNES , Lorena Andrade **Detecção de dano em estruturas baseada em técnicas de aprendizado híbrido**. 2020. Tese (Dissertação mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Civil, 2020.
- 24 BERRAR, Daniel. (2018). **Cross-Validation**. 10.1016/B978-0-12-809633-8.20349-X.
- 25 CARVALHO, A. C. P. L. de. **Introdução às Máquinas de Vetores Suporte** São Carlos - SP, Abril 2003.
- 26 OLIVEIRA ,G. M. O. **Máquina de Vetores Suporte: estudo e análise de parâmetros para otimização de resultado**. 2010. Trabalho de Graduação - Universidade Federal de Pernambuco, CENTRO DE INFORMÁTICA, 2010.
- 27 PRINCIPE, J., EULIANO, N., LEFEBVRE, W.,**Neural and adaptive systems: fundamentals through simulations**. Wiley: London, 2000.
- 28 XU, Yong |HU, Qi FAN, Zizhu QIU, Minna CHEN, Yan LIU, Hong. (2013). **Coarse to fine K nearest neighbor classifier**. Pattern Recognition Letters. 34. 980–986. 10.1016/j.patrec.2013.01.028.

- 29 VITOLA J, POZO F, TIBADUIZA DA, ANAYA M. A Sensor Data Fusion System Based on k-Nearest Neighbor Pattern Classification for Structural Health Monitoring Applications. *Sensors (Basel)*. 2017;17(2):417. Published 2017 Feb 21. doi:10.3390/s17020417
- 30 BARBOSA, F. S.; CREMONA, C. **Determinação dos Parâmetros Modais de Estruturas Submetidas a Excitações Aleatórias** SIMEC, 2002
- 31 J. MAECK, G.d.R., 2002. **Description of z24 benchmark..** In *Mechanical Systems and Signal Processing*. pp. 127–131. doi:doi:10.1006/mssp.2002.1548.
- 32 AMARAL, Rafaelle GENTILE, Carmelo BARBOSA, Flávio CURY, Alexandre. (2020). **VIBRATION-BASED ANOMALY DETECTION USING SPARSE AUTO-ENCODER AND CONTROL CHARTS** . 1335-1347. 10.47964/1120.9108.20087.