

**UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE CIÊNCIAS EXATAS E NATURAIS  
FACULDADE DE COMPUTAÇÃO  
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

**Israël Sèwanou Hounsou**

**Estudo e aplicação de redes neurais recorrentes  
para a imputação de dados em monitoramento  
da integridade de estruturas civis**

Belém-PA

2019

Israël Sèwanou Hounsou

**Estudo e aplicação de redes neurais recorrentes  
para a imputação de dados em monitoramento  
da integridade de estruturas civis**

Trabalho de Conclusão de Curso submetido à  
Universidade Federal do Pará, como requisito  
necessário para obtenção do grau de Bacharel  
em ciência da computação.

Belém-PA

2019

*Dedico, com muito amor e gratidão,  
à minha família.*

# Agradecimentos

Agradeço à minha família por tudo que sempre me proporcionaram e por estarem sempre comigo, aos meus pais Mathias e Eleonore, meu irmão Josaphat em especial. Agradeço também a todas as pessoas que me ajudaram a escrever esse trabalho, me tiraram dúvidas e contribuíram na menor coisa que seja em especial meu orientador Claudomiro e o mestre Moisés Felipe. Sou grato também a todos os meus amigos que fazem parte da minha vida e a tornam melhor. Agradeço também a os professores que fizeram parte dessa minha trajetória até aqui, do ensino infantil até hoje, do Benin até o Brasil, pela sua contribuição no meu conhecimento e sempre me impulsionarem para frente. Por último agradeço ao Programa de Estudantes-Convênio de Graduação (PEC-G) pelo qual eu fiz esse intercambio e a Universidade Federal do Pará (UFPA) por ter mim proporcionado um ensino de qualidade.

*“O homem está condenado a ser livre.”*

*Jean-Paul Charles Aymard Sartre*

*“Ninguém ignora tudo. Ninguém sabe tudo.*

*Todos nós sabemos alguma coisa.*

*Todos nós ignoramos alguma coisa.*

*Por isso aprendemos sempre.”*

*Paulo Freire*

*“L'éducation est l'arme la plus puissante  
qu'on puisse utiliser pour changer le monde..”*

*Nelson Mandela*

# Resumo

Na contemporaneidade, novos desenvolvimentos e métodos tecnológicos estão sendo utilizados como parte de um processo denominado de Monitoramento de Integridade Estrutural (em Inglês *Strutural Health Monitoring* - SHM). O SHM consiste no desenvolvimento de estratégias para detecção, prevenção e caracterização de danos indesejáveis em estruturas civis e mecânicas de comportamento estático (i.e., prédios, pontes, ferrovias) e dinâmicos (i.e., satélites, veículos, equipamentos industriais). Um grande número de sensores coleta as informações em um intervalo de tempo, o que pode gerar uma quantidade elevada de dados que precisam ser transmitidos e armazenados. No entanto, a falha ou outros problemas de funcionamento podem causar a perda de dados, o que impacta diretamente análise e tomada de decisões. Para contornar esse problema, uma nova técnica aparece: A Imputação de dados. Um processo de imputação basicamente substitui os dados perdidos por valores adequados correspondentes a região de dados faltantes; “preenche” os dados perdidos da aplicação com valores plausíveis. Essa imputação é uma prática de preenchimento de dados faltantes e evita a complexidade gerada pelos dados faltantes. Para isto que este trabalho procederá a um estudo comparativo de várias técnicas de imputação referindo-se à imputação por média, moda, regressão, knn e redes neurais recorrentes. Baseado nisto, este trabalho propõe um método de avaliação compara a taxa de erros gerada na detecção de danos. Os métodos foram testados utilizando conjuntos de dados de um sistema de monitoramento instalados na ponte Z-24 (Suíça), que foi submetida a condições de variabilidades diversas, além de ensaios progressivos de dano. A ocorrência de dados ausentes foi feita de maneira artificial. Os resultados mostram que a imputação por rede neural recorrente fornece os melhores resultados.

**Palavras-chave:** Imputação de dados, Monitoramento de Integridade Estrutural, Sensores, Dados faltantes, Redes Neurais Recorrentes.

# Abstract

In contemporary times, new developments and technological methods are being used as part of a process called Structural Health Monitoring (SHM). SHM is the development of strategies for detection, prevention and characterization of undesirable damages in civil and mechanical structures of static behavior (i.e., bridges, railways) and dynamics (i.e., satellites, vehicles, industrial equipment). A large number of sensors collect information over a period of time, which can generate a high amount of data that needs to be transmitted and stored. However, failure or other malfunctions can cause data loss, which directly impacts analysis and decision making. To work around this problem, a new technique appears: A Data Imputation. An imputation process basically replaces lost data with substituted values and “fills” the missing application data with plausible values. This imputation is a practice of filling in missing data and avoids the complexity generated by the missing data. For this, this work will proceed to a comparative study of several imputation techniques referring to imputation by means, fashion, regression, knn and recurrent neural networks. Based on this, this work proposes an evaluation method that compares the error rate generated in the detection of damages. The methods were tested using data sets from a monitoring system installed on the Z-24 bridge (Switzerland), which was subjected to conditions of varying variability as well as progressive damage trials. The occurrence of missing data was done artificially. The results show that recurrent neural networks imputation provides the best results.

**Key-words:** Data Imputation, Structural Health Monitoring, Sensors, Missing Data, Recurrent Neural Networks.

# Lista de ilustrações

Figura 1 – Fluxograma do paradigma SPR para SHM. . . . .	18
Figura 2 – Tipos de Dados Faltantes. . . . .	22
Figura 3 – Exemplo de treinamento de uma Rede Neural . . . . .	31
Figura 4 – Uma revisão das redes neurais cíclicas RNN. . . . .	33
Figura 5 – Problema não linearmente separável . . . . .	35
Figura 6 – BPTT sem gradiente. . . . .	36
Figura 7 – BPTT com gradiente. . . . .	36
Figura 8 – Z-24 Esquema de ponte (direito) e imagem (canto superior esquerda), bem como um cenário de dano introduzido pela falha da cabeça de âncora (canto inferior esquerda). . . . .	37
Figura 9 – Dados Originais das frequências da base Z24. . . . .	39
Figura 10 – Imputação por knn das frequências por cada taxa definido da base Z24. . . . .	48
Figura 12 – Imputação por rnn das frequências por cada taxa definido da base Z24. . . . .	50
Figura 14 – Indicadores de danos por knn e por rnn dos valores imputados da base Z24. . . . .	52

# Lista de tabelas

Tabela 1 – O desempenho da classificação (erros tipo I e II) e o número de componentes para cada algoritmo. . . . .	38
Tabela 2 – Resultados da tecnica de MSE . . . . .	45
Tabela 3 – Resultados da tecnica de MAE . . . . .	45
Tabela 4 – Resultados da tecnica de $R^2$ . . . . .	45
Tabela 5 – Resultados das tecnicas a 10% de imputação . . . . .	46
Tabela 6 – Resultados das tecnicas a 20% de imputação . . . . .	46
Tabela 7 – Resultados das tecnicas a 30% de imputação . . . . .	46
Tabela 8 – Resultados das tecnicas a 60% de imputação . . . . .	46
Tabela 9 – Resultados das tecnicas a 90% de imputação . . . . .	46
Tabela 10 – Resultados do erro do tipo I e II de $R^2$ . . . . .	47

# Sumário

<b>1</b>	<b>Introdução</b>	<b>11</b>
1.1	Trabalhos Relacionados	13
1.1.1	Imputação de dados no contexto de SHM	13
1.1.2	Justificativa	14
1.2	Objetivos	15
1.2.1	Objetivo Geral	15
1.2.2	Objetivos Específicos	15
<b>2</b>	<b>Monitoramento de Integridade Estrutural</b>	<b>17</b>
2.1	Avaliação operacional	18
2.2	Aquisição de dados	19
2.3	Extração de features	19
2.4	Modelagem estatística	20
<b>3</b>	<b>Tipos de dados faltantes</b>	<b>21</b>
3.1	Dados faltantes	21
3.2	Algoritmo para dado faltante completamente aleatório	23
3.3	Algoritmo para Dados faltantes aleatório	24
3.4	Algoritmo para Dados faltantes não aleatório	25
3.4.1	Algoritmo para Desaparecimento dependendo do seu Valor Próprio - MIV	25
3.4.2	Algoritmo para Desaparecimento dependendo de Variáveis não observadas - MuOV	25
<b>4</b>	<b>Métodos de imputação</b>	<b>27</b>
4.1	Imputação pela média	27
4.2	Imputação pela moda	28
4.3	Imputação pela regressão linear	28
4.4	Imputação pelo k-vizinho mais próximo (knn)	29
4.5	Rede Neural	30
4.6	Redes neurais recorrentes	32
4.7	Retropropagação	34
4.8	Retropropagação através do tempo	35
<b>5</b>	<b>Metodologia de testes</b>	<b>37</b>
5.1	Aquisição de dados	37
5.2	Definição de Parâmetros	39
5.3	Extração de características	40
5.4	Amputação e imputação de danos	40
5.5	Critérios tradicionais de avaliação	40

5.5.1 Mahalanobis squared-distance . . . . .	42
<b>6 Resultados . . . . .</b>	<b>43</b>
6.1 Determinação de características sensíveis a danos . . . . .	43
6.2 Comportamento do sinal à perda de dados . . . . .	43
6.2.1 Comportamento do sinal como o knn . . . . .	44
6.2.2 Comportamento do sinal com a rede neural recorrente . . . . .	44
6.3 Comparação dos métodos de imputação de dados . . . . .	45
6.3.1 MSE, MAE e $R^2$ . . . . .	45
6.3.2 Erro do tipo I e tipo II . . . . .	47
<b>7 Considerações Finais . . . . .</b>	<b>53</b>
7.1 Trabalhos Futuros . . . . .	53
<b>Referências . . . . .</b>	<b>55</b>

# 1 Introdução

Melhoria e avaliação mais contínua das condições das estruturas civis tem sido demandada por nossa sociedade para melhor enfrentar os desafios apresentados pelo envelhecimento da infraestrutura civil. Os sistemas de gerenciamento estrutural (Em Inglês Structural management systems - SMSs) planejam cobrir todas as atividades realizadas durante a vida útil das estruturas de engenharia, considerando a segurança pública, as restrições orçamentárias das autoridades e a funcionalidade da rede de transporte. Eles possuem mecanismos para garantir que as estruturas sejam regularmente inspecionadas, avaliadas e mantidas de maneira adequada. Assim, um SMS é desenvolvido para analisar fatores econômicos e de engenharia e para atender às autoridades na determinação de como e quando tomar decisões quanto à manutenção, reparo e reabilitação de estruturas (FIGUEIREDO; MOLDOVAN; MARQUES, 2013; FARRAR; WORDEN, 2013).

No entanto, os SMSs ainda dependem de inspeções estruturais, especialmente nas inspeções visuais qualitativas e não necessariamente consistentes, que podem impactar a avaliação estrutural e, conseqüentemente, as decisões de manutenção, bem como evitar colapsos estruturais (WENZEL, 2009). Nos últimos anos, a disciplina de Monitoramento de Integridade Estrutural (SHM) surgiu para auxiliar a gestão estrutural com informações mais confiáveis e quantitativas; ele é baseado na técnica da Impedância Eletromecânica que permite de detectar alterações em estruturas, possibilitando a identificação e o reparo de danos (SANTOS et al., 2016). A técnica baseia-se em obter assinaturas de impedância da estrutura monitorada, em diversos momentos da operação da mesma. Embora o SMS já tenha sido aceito pelos gestores estruturais ao redor do mundo (HU et al., 2017; WORDEN et al., 2015), e com limitações inerentes impostas pelas inspeções visuais, o SHM está se tornando cada vez mais atraente devido à sua potencial capacidade de detectar etapas invariáveis de danos e quase em tempo real, com os conseqüentes benefícios de segurança de vida e econômicos (FARRAR; WORDEN, 2013; WORDEN et al., 2007).

O processo envolve a observação de um sistema estrutural ao longo do tempo usando medições de resposta periodicamente amostradas de uma série de sensores, a extração de características sensíveis a danos dessas medições e a análise estatística dessas características para discriminar a condição estrutural real por curto ou longo prazo; Então uma vez que a condição normal tenha sido aprendida com sucesso, o modelo pode ser usado para avaliação de condição rápida para fornecer, em tempo quase real, informação confiável a respeito da integridade da estrutura.

O monitoramento é dado com sensores ligados na estrutura que coletam informações sobre o estado atual da mesma. Os dados coletados são transformados em características

sensíveis a dano (SANTOS et al., 2016). Para realizar essa detecção de danos existem vários métodos e algoritmos de aprendizado de máquina que podem ser aplicados nos dados. Esses métodos podem analisar vários tipos de dados como vibração e pressão para criar modelos estatísticos de detecção de dano (FIGUEIREDO; MOLDOVAN; MARQUES, 2013). Visto que os sensores muitas vezes não tem capacidade de processar os dados, é necessário enviar eles pela rede para o local onde eles são processados. Um número grande de sensores pode sobrecarregar a rede pela qual os dados são enviados, assim como os bancos de dados que armazenam os mesmos (MADDEN, 2010). Por esse motivo é muito comum nos sistemas atuais de SHM incorporar métodos de compressão de dados (LIMA et al., 2016).

A compressão de dados também é uma parte inerente da maioria dos procedimentos de extração de recursos. Infelizmente, as variações operacionais e ambientais (por exemplo, temperatura, carga operacional, umidade e velocidade do vento) geralmente surgem como efeitos indesejados nos recursos sensíveis a danos e geralmente mascaram as alterações causadas por danos, o que pode influenciar negativamente na identificação dos danos (SOHN, 2007).

Com base no tratamento de dados adequado, informações importantes da dinâmica estrutural podem ser extraídas e usadas como características sensíveis a dano afim de detectar danos estruturais precoces e progressivos, aumentando assim a segurança, evitando colapsos e apoiando o processo de tomada de decisão sobre manutenção, reparo e reabilitação (SANTOS et al., 2016). O ponto crítico para os sistemas de SHM é a perda ou omissão de dados devido à falha do sensor ou outros problemas de funcionamento, o que influencia a análise e tomada de decisões subsequentes (CHEN et al., 2018), pode até haver uma perda completa de informações devido a uma falha abrupta dos sensores (BALABAN et al., 2010).

Sendo assim para superar esses problemas dos dados faltantes, a imputação de dados apareceu como alternativa. Utilizar o processo de imputação para preencher os dados perdidos é recomendado para evitar a perda completa dos dados, algo que pode levar à conclusões enganosas (SCHMITT; MANDEL; GUEDJ, 2015). Por isso várias estratégias inspiradas em estatística e aprendizado de máquina foram desenvolvidas para resolver o problema da imputação de dados (JM et al., 2010; PJ et al., 2015; SOVILJ et al., 2016).

Apesar dos recentes avanços na área e dos benefícios dos métodos de imputação baseados em computação evolucionária, existem desafios de pesquisa em aberto que limitam a plena utilização das abordagens existentes. A seguir, são descritos os algoritmos que estão mais relacionados ao contexto Imputação de dados e são comparados para analisamos qual desses algoritmos é mais apropriado no nosso contexto de Monitoramento de Integridade Estrutural.

## 1.1 Trabalhos Relacionados

A revisão desses estudos será feita a partir de uma diferenciação entre duas categorias. Na primeira abordaremos a imputação de dados no contexto de SHM principalmente na área de sensores sem fio, e proporemos novas técnicas de imputação que é a imputação pela rede neural recorrente. Na segunda categoria faremos a comparação dos diferentes métodos de imputação de dados, porém sem um foco específico na área de SHM.

### 1.1.1 Imputação de dados no contexto de SHM

A grande maioria dos algoritmos de aprendizado de máquina e mineração de dados pressupõe que os dados disponíveis estão prontos para uso, isto é, já está normalizado (quando necessário), não tem ruído, erros de digitação nem valores ausentes. Os praticantes desses campos passam seus dados para etapas de pré-processamento, que podem envolver o uso de vários algoritmos, com o objetivo de tornar os dados prontos para serem usados por algoritmos de aprendizado. Uma tarefa frequente nos dados de pré-processamento é o tratamento de valores de atributos ausentes (BERTINI; NICOLETTI; ZHAO, 2014).

Provavelmente, a prática mais popular para lidar com padrões com valores de atributos ausentes é descartá-los. Dependendo da aplicação e do volume de dados disponíveis, esta pode ser uma opção conveniente: fácil, rápida de ser implementada e não interfere com os dados (no sentido de introduzir dados gerados artificialmente). No entanto, dependendo da escassez dos dados, esta não é uma opção a ser considerada; um processo conhecido como imputação de dados deve ser empregado no lugar. Um processo de imputação basicamente substitui os dados perdidos por valores imputados (SCHAFER, 1999).

Na literatura existem vários algoritmos que implementam processos de imputação; Veja, por exemplo, (GRZYMALA-BUSSE; HU, 2001; MYRTVEIT; STENSRUD; OLSSON, 2001). Uma maneira mais inteligente e mais útil de lidar com o problema do valor ausente é substituir (imputar) uma falta valor com alguma estimativa para esse valor; no entanto, a imputação deve ser aplicada com cuidado. Em geral, os algoritmos de imputação determinam os valores ausentes com base nos outros valores do mesmo atributo que estão presentes nos dados, levando em consideração a classe (ou não) à qual os padrões pertencem. Tipicamente, algoritmos com tais características exigem um conjunto de dados de tamanho razoável para induzir os valores em falta, fazendo com que, dependendo do volume de dados disponíveis, seja impossível de ser considerado. Apenas alguns algoritmos focam no (s) padrão (ões) com valores de atributo ausentes, o que é uma maneira intuitiva de abordar tal tarefa, temos também as rede neurais que fazem as imputação seguindo varios treinamentos.

As redes neurais são referidas na literatura como neurocomputadores, processadores paralelamente distribuídos. Eles tiram seus poderes computacionais através de suas

estruturas maciçamente paralelamente distribuídas e de suas habilidades de aprenderem e, portanto, de generalizarem. A rede neural recorrente é uma classe de redes neurais que inclui conexões ponderadas dentro de uma camada e como eles tem loops, podem armazenar informações ao processar novas entradas. Por isso que as imputações no contexto de SHM por rede neural recorrente poderia ser um método mais eficiente.

### 1.1.2 Justificativa

Posto que a imputação de dados pode ser tratada como um problema de otimização, não há na literatura uma formalização. Um desafio de pesquisa é propor uma definição formal da imputação de dados como um problema de otimização, de forma a fornecer um arcabouço que conceda maior flexibilidade e robustez às soluções nela baseadas. Com uma formalização apropriada para a imputação de dados, é possível reduzir o espaço de busca em bases de dados complexas (com alta dimensionalidade e grande quantidade de valores ausentes) por meio de adoção de estratégias de estratificação (EIBEN; SMITH, 2015).

Existem diversos trabalhos dedicados ao desenvolvimento de novas técnicas de imputação de dados dentro do contexto de SHM, mas são trabalhos focados na construção de novos métodos para a área de sensores sem fio e não na comparação entre os diversos métodos já existentes. Há diversas formas de avaliar o desempenho de métodos de imputação, uma das mais usuais é realizada por meio de testes utilizando conjuntos de dados artificiais, possibilitando a adoção do erro quadrático médio calculado entre o valor real e o predito pelo método de imputação. No entanto, algumas discussões acerca dessa abordagem devem ser destacadas:

i) A indução da ausência de dados nem sempre reflete o modelo real de aleatoriedade da ausência de dados, conseqüentemente, um método com um bom desempenho neste tipo de cenário poderá apresentar resultados enviesados em casos reais (LITTLE; RUBIN, 2014; JW, 2009)

ii) Alguns autores sugerem que a consideração de medidas baseadas na tarefa de modelagem, como por exemplo a classificação de padrões, é imprescindível, uma vez que a tarefa de modelagem é o objetivo final do processo de análise dos dados (LAENCINA; SANCHO-GÓMEZ; FIGUEIRAS-VIDAL, 2010), e ainda, alguns estudos apontam que uma melhor acurácia preditiva do método de imputação não conduz a um menor viés no processo de modelagem (HRUSCHKA et al., 2009)

iii) Há também discussões sobre a utilização do erro quadrático médio como única medida de desempenho, pois tal erro, sozinho, não reflete a variabilidade da amostragem e incertezas a respeito de um modelo de ausência de dados (LITTLE; RUBIN, 2014);

iv) Por fim, discute-se a proporcionalidade entre as medidas de desempenho, visto que algumas delas apresentam comportamentos conflitantes; enquanto uma otimiza, a

outra decaí. Deste modo, um dos desafios da literatura é estudar estratégias flexíveis à adição de diferentes medidas de desempenho, e ainda, propor métodos que lidem de forma satisfatória com medidas de desempenho conflitantes;

O nosso trabalho se propõe a realizar uma validação em cima do domínio do problema, utilizando técnicas de detecção de danos que já foram amplamente testadas na literatura (COSTA, 2018). Dentro deste contexto, para a etapa de detecção de danos a escolha dos algoritmos utilizados se deu por serem métodos de clusterização simples, bastante conhecidos e eficientes na literatura de aprendizado de máquina. Essas técnicas variam de clusterização em centroides e por densidade, *soft* e *hard*, paramétricas e não paramétricas. Com toda essa variedade se espera que sejam encontradas mais combinações que possam ser usadas em SHM, ao avaliar o método de imputação utilizado em conjunto com a técnicas de detecção de danos.

Para o desenvolvimento do nosso trabalho, para executar o processo de extração de características a partir do sinal, desenvolveremos uma versão no MATLAB.

## 1.2 Objetivos

### 1.2.1 Objetivo Geral

O objetivo desse trabalho é comparar, dentro do domínio específico de SHM, as técnicas de imputação de dados: O KNN e a redes neurais recorrentes (RNN). Os resultados permitirão definir o desempenho de tais técnicas tratando especificamente dessa área, levando em conta as diferentes taxas de dados faltantes e a performance computacional de cada método.

### 1.2.2 Objetivos Específicos

Considerando o desenvolvimento do trabalho e o objetivo geral apresentado, destacam-se os seguintes objetivos específicos:

- Revisão e estudo da literatura de SHM, tanto na área de imputação de dados quanto na área de detecção de danos;
- Avaliar o impacto de diferentes taxas de dados faltantes na sensibilidade do sinal, a fim de analisar em qual percentual o sinal começa a perder suas características.
- Comparar as técnicas de imputação de dados, sendo elas o knn e a RNN, no domínio específico de SHM.
- Avaliar as técnicas selecionadas para imputação e sua consequência na detecção de dano, através de critérios tradicionais de avaliação.

- Implementação de framework desenvolvido em Matlab para extração de features a partir do sinal.

## 2 Monitoramento de Integridade Estrutural

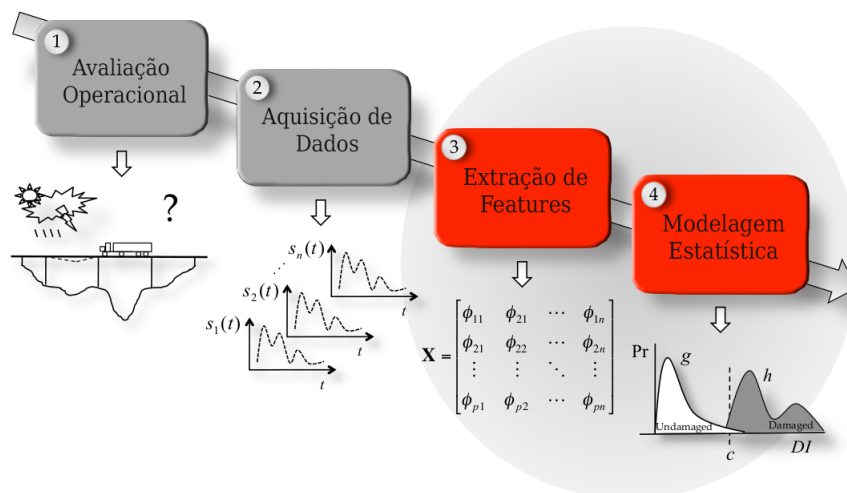
O campo de engenharia interdisciplinar dedicado ao monitoramento e avaliação da saúde estrutural e da durabilidade é o Monitoramento de Integridade Estrutural (SHM). A tecnologia SHM integra sensoriamento remoto, materiais inteligentes e sistemas de conhecimento baseados em computador para permitir que os engenheiros vejam como as estruturas construídas estão se desenvolvendo ao longo do tempo. É particularmente útil para monitorar remotamente grandes sistemas de infraestrutura, como pontes e barragens, e sistemas mecânicos de alto perfil, como aeronaves, naves espaciais, navios, estruturas offshore e tubulações, onde o desempenho é crítico, mas o monitoramento no local é difícil ou mesmo impossível. O Monitoramento de Integridade Estrutural com sensores ativos de Wafer Piezoelétrico é o primeiro livro abrangente a fornecer informações básicas, modelagem teórica e exemplos experimentais sobre as principais tecnologias envolvidas no SHM (ZAGRAI et al., 2010).

O monitoramento de integridade estrutural refere-se ao processo de implementação de uma estratégia de detecção e caracterização de danos para estruturas de engenharia. Aqui, dano é definido como alterações no material e/ou propriedades geométricas de um sistema estrutural, incluindo mudanças nas condições de contorno e conectividade do sistema, que afetam adversamente o desempenho do sistema. O processo SHM envolve a observação de um sistema ao longo do tempo usando medições de respostas dinâmicas amostradas periodicamente de uma matriz de sensores, a extração de recursos sensíveis a danos dessas medições e a análise estatística desses recursos para determinar o estado atual da integridade do sistema. Para o SHM de longo prazo, a saída desse processo é uma informação atualizada periodicamente sobre a capacidade da estrutura de desempenhar sua função pretendida à luz do inevitável envelhecimento e degradação resultante dos ambientes operacionais. Após eventos extremos, como terremotos ou explosões, o SHM é usado para triagem rápida de condições e visa fornecer, em tempo quase real, informações confiáveis sobre a integridade da estrutura. Segundo (DAWSON, 1976) a inspeção de infraestrutura desempenha um papel fundamental na segurança pública no que diz respeito ao acúmulo de danos a longo prazo e a cenários de eventos extremos. Como parte dos rápidos desenvolvimentos em tecnologias orientadas a dados que estão transformando muitos campos da engenharia e da ciência, as técnicas de aprendizado de máquina e de visão computacional são cada vez mais capazes de diagnosticar e classificar de forma confiável os dados de imagem, que têm aplicações claras em contextos de inspeção.

A literatura SHM comumente aborda esse processo com um problema de reconhecimento de padrões estatísticos (FARRAR; DOEBLING; NIX, 2001). Podemos assim identificar quatro etapas para o processo: Avaliação operacional, aquisição de dados,

extração de características e modelagem estatística, conforme ilustrado na Figura 1 (FIGUEIREDO, 2010). Essas etapas serão explicadas com mais detalhes a seguir. Os blocos pintados de vermelho e destacados pelo círculo cinza são as etapas que serão abordadas de maneira detalhada dentro do nosso trabalho.

Figura 1 – Fluxograma do paradigma SPR para SHM.



Fonte: FIGUEIREDO, E. J. F. (FIGUEIREDO, 2010)

## 2.1 Avaliação operacional

Realizar uma avaliação operacional (FIGUEIREDO, 2010) é o primeiro passo para desenvolver um sistema de SHM. Essa avaliação procura responder a quatro questionamentos no que diz respeito à implementação de um sistema de monitoramento (WORDEN et al., 2007):

- i) Qual é a justificativa de segurança de vida e/ou econômica para realizar o monitoramento de integridade estrutural?
  - ii) Como os danos são definidos para o sistema que está sendo investigado e, para várias possibilidades de danos, quais casos são os mais preocupantes?
  - iii) Quais são as condições sob as quais o sistema a ser monitorado funciona, tanto em termos operacionais quanto ambientais?
  - iv) Quais são as limitações no processo de aquisição de dados no ambiente operacional?
- Essa fase define e quantifica o dano a ser identificado, além de definir os benefícios a serem obtidos com a implantação do sistema de monitoramento de integridade estrutural (FIGUEIREDO; MOLDOVAN; MARQUES, 2013).

A avaliação operacional inicia definindo as limitações em relação ao que será monitorado e como será feito esse monitoramento, além de ajustar essa supervisão para os aspectos únicos que possam existir em cada sistema e para as características únicas dos danos a serem detectados (CZARNECKI, 2004; FARRAR; WORDEN, 2013).

## 2.2 Aquisição de dados

O objetivo da aquisição de dados é fazer somente as medições, o sensor não tem responsabilidade para realizar a detecção de danos. Esses dados serão usados posteriormente para gerar informação necessária sobre a existência de danos ou não (CZARNECKI, 2004).

A tarefa de aquisição de dados do processo de monitoramento de integridade estrutural engloba a seleção do número e dos tipos de sensores a serem usados, os locais onde os sensores devem ser colocados e o hardware que será utilizado para as tarefas de aquisição, armazenamento e transmissão de dados (SOHN, 2006).

A sensibilidade do sensor à excitação de baixo nível, os procedimentos de interrogação de dados, bem como o intervalo em que os dados devem ser coletados, são outras questões que devem ser abordadas. Por exemplo, em aplicações onde a segurança de vida é um esforço crítico, como monitoramento de terremotos, pode ser prudente coletar dados imediatamente antes e em intervalos periódicos após um grande evento. Por outro lado, identificar ligeiramente as mudanças na rigidez e propriedades geométricas é a principal preocupação, então pode ser necessário coletar dados quase continuamente em intervalos de tempo relativamente curtos, uma vez que alguma rachadura crítica tenha sido identificada. O tipo de estratégia é altamente dependente das questões abordadas durante a avaliação operacional. Todos esses conteúdos podem afetar mais ou menos diretamente as leituras coletadas, quanto à presença e localização dos danos.

## 2.3 Extração de features

A parte do processo de SHM que demanda muitos esforços de pesquisa é a identificação de características de dados que permitem distinguir entre estados não danificados e danificados da estrutura monitorada (CZARNECKI, 2004). Uma característica sensível a dano é uma quantidade extraída dos dados de resposta estrutural que é correlacionada com a presença de dano em uma estrutura (por exemplo, parâmetros modais, deslocamentos máximos, parâmetros do modelo de regressão e erros residuais), indicando a presença (ou não) de danificar em uma estrutura. Um recurso sensível a danos adequado varia de acordo com o nível de dano na estrutura. No entanto, o tipo de recurso difere do tipo de estrutura e do objetivo do monitoramento. Fundamentalmente, o processo de extração de recurso é baseado na adaptação de algum modelo, tanto física quanto baseada em dados, para os dados de resposta medidos. Os parâmetros desses modelos, ou os erros preditivos associados a eles, tornam-se os recursos sensíveis a danos. Geralmente, um grau de processamento de sinal é necessário para extrair recursos efetivos.

## 2.4 Modelagem estatística

A relação funcional entre os recursos selecionados e o estado de dano da estrutura é muitas vezes difícil de definir com base em procedimentos de análise de engenharia baseados em física. Portanto, os modelos estatísticos são derivados usando técnicas de aprendizado de máquina. Esses algoritmos geralmente se enquadram em três categorias:

- (i) classificação de grupo,
- (ii) análise de regressão e
- (iii) detecção discrepante ou de novidade.

O algoritmo apropriado a ser usado depende da capacidade de realizar aprendizagem supervisionado ou não supervisionado. No contexto das aplicações SHM, a aprendizagem supervisionada é referida ao caso em que estão disponíveis exemplos de dados de condições danificadas e não danificadas; A classificação de grupos e a análise de regressão são frequentemente usadas para esse propósito. Por outro lado, a aprendizagem não supervisionada surge quando apenas os dados da estrutura não danificada estão disponíveis para treinamento, onde os métodos de detecção outliers ou novidade são a classe primária de algoritmos usados nessa situação. No entanto, para infraestruturas de alto investimento de capital, como as civis, o aprendizado não supervisionado é muitas vezes necessário porque apenas os dados da condição não danificada estão disponíveis.

Os modelos estatísticos são usados para minimizar as falsas indicações de danos. As falsas indicações de dano se enquadram em duas categorias:

- (i) indicação de dano falso-positivo (indicação de dano quando não existe)
- (ii) indicação de dano falso-negativo (nenhuma indicação de dano quando dano estiver presente) (FARRAR; WORDEN, 2013).

Erros do primeiro tipo são indesejáveis, pois causam tempo de inatividade desnecessário e consequente perda de receita, bem como perda de confiança no sistema de monitoramento. Mais importante ainda, há problemas de segurança claros se ocorrerem erros de classificação do segundo tipo (CZARNECKI, 2004).

## 3 Tipos de dados faltantes

Neste capítulo é exposta a importância da imputação de dados, para tanto, vamos explicar os vários tipos de dado faltante e as razões que levam a imputação nas suas diversas formas. Vários métodos de imputação foram estudados: método de imputação por moda, pela média, por regressão, por knn e por redes neurais recorrentes. Ao final apresentaremos as comparações para ver quais são os métodos mais usados nesta situação.

### 3.1 Dados faltantes

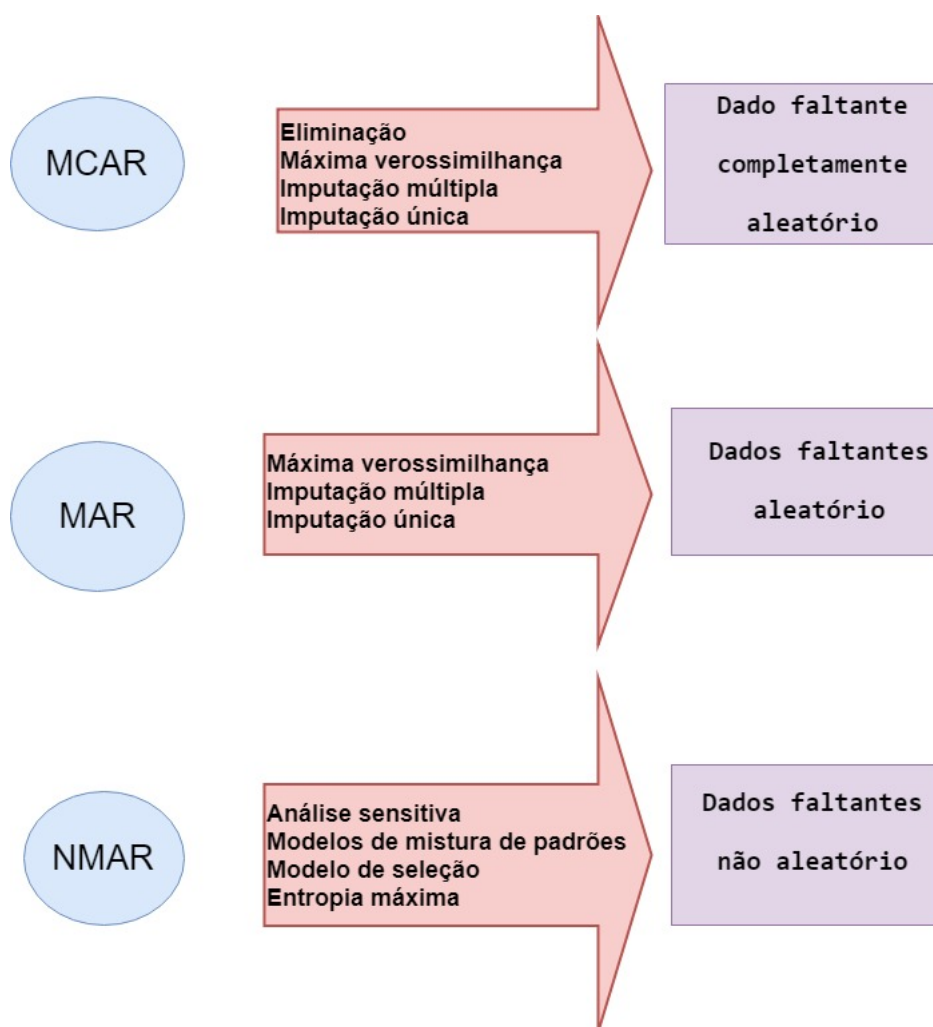
Varias razões diferentes podem causar dados em falta em bancos de dados do mundo real. Identificar qualquer padrão no dado faltante é um aspecto fundamental ao conceber métodos para lidar com as observações que faltam. Segundo(GARCIARENA; SANTANA, 2017), ele mostra que em particular, o tipo de dado faltante pode impactar diretamente a qualidade das previsões dos métodos de classificação aplicados aos dados. Portanto, vários trabalhos foram dedicados a caracterizar os tipos de dado faltante e sugerir algoritmos para a imputação. Nesta seção, revisamos as classes de dado faltante mais aceitas e seus efeitos esperados sobre o comportamento das técnicas de classificação supervisionadas.

- Dado faltante completamente aleatório (em inglês *Missing Completely at Random* - MCAR): quando as falhas de medição do banco de dados ocorrem aleatoriamente, não há um padrão específico a ser identificado. O impacto do MCAR em um algoritmo de classificação dependerá da distribuição de dado faltante sobre os dados. Quanto mais uniforme for a distribuição do dado faltante, menor será o viés a ser introduzido no banco de dados.
- Dados faltantes aleatório (em inglês *Missing At Random* - MAR): Dado faltante é catalogado como MAR quando um padrão pode ser identificado, isto é, podemos encontrar um fator comum em todas as observações com valores omissos. Por exemplo, descobrimos que quando uma determinada variável (sem dado faltante) aceita valores extremos para uma observação, outras duas variáveis (o conjunto que se refere aos dados presentes e o que corresponde aos dados omissos (faltantes)) tendem a estar ausentes para a mesma observação.
- Dados faltantes não aleatório (em inglês *Missing Not At Random* - MNAR: Este tipo dado faltante é semelhante ao MAR. No entanto, neste caso, os valores que causam a falta de outros não são conhecidos, isso pode ter duas origens:

- Desaparecimento dependendo de Variáveis não observadas (em inglês *Missingness depending on unobserved Variables* - MuOV): Uma das razões pelas quais esses valores não são conhecidos pode ser que simplesmente eles não foram observados.
- Desaparecimento dependendo do seu Valor Próprio (em inglês *Missingness depending on its Value Itself* - MIV): Um elemento pode estar faltando dependendo do próprio valor. Isso pode acontecer quando uma variável tira um valor do seu intervalo de representação.

Como podemos ver resumidamente na figura 2 a seguir:

Figura 2 – Tipos de Dados Faltantes.



Fonte: Produzido pelo autor

Em geral, não é possível identificar o tipo de dado faltante do MCAR, pois em bancos de dados reais não há como rastrear a causa desse dado faltante. O MCAR pode ser causado por uma enorme variedade de razões, desde a perda de dados durante uma transferência de informação, até a recusa de uma pessoa em fornecer dados pessoais em uma pesquisa, etc. (BATISTA; MONARD, 2003; HERNANDEZ-PEREIRA;

ALVAREZ-ESTÉVEZ; MORET-BONILLO, 2015). Como dito acima, assumindo que os valores ausentes são uniformemente distribuídos, o conjunto de dados não experimenta uma perda considerável de informações, desde que a quantidade de valores omissos não seja significativa, mesmo o descarte de observações contendo dado faltante não terá necessariamente um impacto na classificação posterior. No entanto, mesmo que a quantidade de informações perdidas em relação a observações perdidas possa ser pequena, a qualidade do método de imputação pode ser tão importante quanto em outros tipos de dado faltante.

O tipo de dado faltante do MAR não é tão comum quanto o MCAR, mas é mais fácil inferir sua origem estudando outras variáveis do conjunto de dados. Por exemplo, em uma situação em que as pessoas são questionadas sobre seus hábitos e saúde, algumas informações sobre o estilo de vida sedentário podem estar disponíveis. No entanto, enquanto alguns indivíduos podem estar abertos para compartilhar informações sobre seu peso, outros sujeitos (mais provavelmente aqueles com uma condição de sobrepeso) podem relutar mais em divulgar esse tipo de informação. Este exemplo ilustra situações em que uma causa para o MAR pode ser inferida a partir de uma análise das características do banco de dados.

O tipo MAR de dado faltante pode ser uma fonte potencial de problemas para o desempenho oferecido pelos algoritmos de classificação. Como neste caso existe uma razão subjacente para o dado faltante, é provável que as observações contendo dados faltantes sejam semelhantes entre si e sejam marcadas na mesma classe. Isso pode levar a um banco de dados desbalanceado que afetará potencialmente a classificação. Nesse caso, descartar dados não é uma opção recomendável e o uso de mensagens instantâneas é um requisito.

Finalmente, o MNAR apresenta uma situação consideravelmente mais difícil. Seguindo o exemplo anterior, a tarefa se tornaria muito mais tediosa se não tivéssemos perguntado sobre outros parâmetros médicos e de estilo de vida (MuOV). Outro cenário precisa ser abordado quando um indivíduo se envergonha e se recusa a divulgar. Essa variável provavelmente depende apenas de si mesma. Neste segundo caso, teríamos MIV. Essas duas situações são as mais problemáticas, uma vez que podem ser tão prejudiciais quanto o MAR para os dados, mas podem ser facilmente identificadas erroneamente como MCAR, como resultado da impossibilidade de identificar um padrão nas variáveis não observadas.

## 3.2 Algoritmo para dado faltante completamente aleatório

Para esta instância, seguimos um algoritmo simples, no qual dois números aleatórios são gerados e usados como índices em nosso banco de dados. O elemento que eles apontam tem seu valor alterado para “NaN”. Esse processo é repetido até que a porcentagem predefinida seja atingida. O pseudocódigo é mostrado no algoritmo 1. Sendo MD as

porcentagens gerada, 10%, 20%, 30%, 60% e 90% X= o numero de valor observado Y o numero de variável de dado NaN= Not a Number I = comprimento de dado observado e J o comprimento de dado das variaveis

---

### Algoritmo 1: MCAR

---

**Entrada:**

- 1 data : BasedeDado
- 2 mdp: MD percentage

**Saída:** Base de dado com mdp % generated MD

**3 início**

- 4 |  $x = \text{numObservado}(\text{dado})$
- 5 |  $y = \text{numVariavel}(\text{dado})$
- 6 | **para**  $i \in [0, x.y.mdp//100]$  **faça**
- 7 | | data [ $\text{random}([0, x]), \text{random}([0, y])$ ] = “NaN”
- 8 | **fim**
- 9 | **retorna** (dado)

**10 fim**

---

Este algoritmo gera simplesmente duas coordenadas da matriz de dados e ajusta a entrada correspondente no banco de dado para “NaN”.

### 3.3 Algoritmo para Dados faltantes aleatório

Este método é menos direto do que o anterior, uma vez que primeiro precisamos determinar qual variável é a causa do dado faltante. Nossa implementação assume uma única variável como causativa, mas as variáveis causativas do MAR podem ser múltiplas. O próximo passo é escolher as variáveis que terão alguns de seus valores como ausentes. Nós chamamos essas variáveis de dependentes. Como as variáveis causadoras de MAR tendem a causar dado faltante quando assumem valores extremos, as observações com valores mínimos para essas variáveis foram escolhidas para introduzir “NaN” em suas variáveis dependentes. Aqui,  $\text{maxInt}$  significa o inteiro máximo interpretável para uma linguagem de programação, e é usado para tornar esse índice inelegível. O pseudocódigo que descreve este método é mostrado no algoritmo 2. Sendo MD as porcentagens gerada, 10%, 20%, 30%, 60% e 90% X= o numero de valor observado Y o numero de variável de dado NaN= Not a Number I = comprimento de dado observado e J o comprimento de dado das variaveis

Este algoritmo primeiro escolhe a variável causativa e copia seus valores para outro vetor (aux), de modo que os dados originais não sejam modificados para além da introdução dos valores “NaN”. Em seguida, escolhemos quais variáveis perderão seus valores (MDVariables). O primeiro loop determina quais observações estarão perdendo valores para as MDVariables. Ele seleciona os valores mínimos para a variável causativa (aux) e

**Algoritmo 2: MAR**


---

**Entrada:**

- 1 data : BasedeDado
- 2 mdp: MD percentage
- 3  $nV$ : número de variáveis que estão perdendo seus valores

**Saída:** Base de dado com mdp % gerado MD

4 **início**

- 5      $x = \text{numObservado}(\text{dado})$
- 6      $y = \text{numVariavel}(\text{dado})$
- 7     **para**  $i \in [0, x.y.mdp/100//nV]$  **faça**
- 8         Observado[ $i$ ] = random([0, $x$ ])
- 9     **fim**
- 10    **para**  $i \in [0, \text{comprimento}(\text{observado})]$  **faça**
- 11         **para**  $j \in [0, \text{comprimento}(MD\text{variavel})]$  **faça**
- 12             dado[observado[ $i$ ], MDvariavel[ $j$ ]= “NaN”
- 13         **fim**
- 14     **fim**
- 15    **retorna** (dado)
- 16 **fim**

---

os torna ilegíveis atribuindo-lhes um número enorme. Finalmente, os loops aninhados usam as informações para introduzir o dado faltante.

### 3.4 Algoritmo para Dados faltantes não aleatório

#### 3.4.1 Algoritmo para Desaparecimento dependendo do seu Valor Próprio - MIV

- Nessa subseção vamos mostrar os dois algoritmos do Desaparecimento dependendo do seu Valor Próprio - MIV e Desaparecimento dependendo de variáveis não observadas - MuOV

O algoritmo do desaparecimento dependendo do seu Valor Próprio - MIV é muito semelhante ao utilizado para criar o padrão MAR de dado faltante, mas em vez de gerar variáveis que perderão seus valores dependendo dos valores de uma variável causativa, será o próprio causador que perde variáveis. O pseudocódigo é mostrado no algoritmo 3. Sendo MD as porcentagens gerada, 10%, 20%, 30%, 60% e 90% X= o numero de valor observado Y o numero de variável de dado NaN= Not a Number I = comprimento de dado observado e J o comprimento de dado das variaveis

**Algoritmo 3: MIV**


---

**Entrada:**

- 1 data : Base de Dados
- 2 mdp: MD percentage
- 3  $nV$ : número de variáveis que estão perdendo seus valores

**Saída:** Base de dados com mdp % gerado MD

- 4 **início**
- 5      $x = \text{numObservado}(\text{dado})$
- 6      $y = \text{numVariavel}(\text{dado})$
- 7     Observado=[] Causativo = random([0,y],  $nV$ )
- 8     **para**  $i \in [0, \text{comprimento}(\text{causativo})]$  **faça**
- 9         aux = dado[:, causativo[i]] **para**  $j \in [0, x.y.mdp/100//nV]$  **faça**
- 10             observado[j] = minIndex(aux) aux[observado[j]] = maxInt
- 11         **fim**
- 12         **para**  $j \in [0, \text{comprimento}(\text{observado})]$  **faça**
- 13             dado[observado[j], causativo]= “NaN”
- 14         **fim**
- 15     **retorna** (dado)
- 16     **fim**
- 17 **fim**

---

### 3.4.2 Algoritmo para Desaparecimento dependendo de Variáveis não observadas - MuOV

- O algoritmo do Desaparecimento dependendo de Variáveis não observadas - MuOV é também bastante semelhante ao proposto para gerar o tipo MAR dado faltante, mas neste caso a variável causadora não é observada. Portanto, as observações que terão valores omissos serão escolhidas aleatoriamente.

Como indicado anteriormente, este algoritmo segue a mesma estrutura, mas como neste caso as variáveis causais são desconhecidas, as observações para perder seus valores serão escolhidas aleatoriamente.

## 4 Métodos de imputação

Existem duas maneiras principais de lidar com dado faltante. Ignorar observações com dados perdidos é geralmente uma boa escolha quando a cardinalidade dos valores omissos é relativamente pequena e o dado faltante é homogeneamente distribuído. No entanto, quando essas falhas de medição são concentradas em uma única variável, ou quando ignorá-las supõe uma grande perda de informações, consideramos técnicas para preencher as lacunas. Isso é essencialmente o que a imputação faz. Várias estratégias têm sido propostas para este propósito e podem exibir diferenças importantes em termos de complexidade e qualidade de produção (BATISTA; MONARD, 2003). A Seção a seguir apresentará vários métodos de imputação como o knn e a rede neural recorrente para o nosso trabalho.

### 4.1 Imputação pela média

A técnica de imputação pela média permite que se substitua um valor omissos pela média dos valores presentes na variável de interesse. Às vezes, esta abordagem pode conduzir os valores imputados a resultados razoáveis, entretanto não leva em consideração a relação entre os atributos, que é útil no processo de tratamento dos valores faltantes. (HRUSCHKA; HRUSCHKA; EBECKEN, 2001) argumentam que é mais importante preservar as relações entre os atributos do que obter previsões mais precisas. A imputação por média é um dos métodos de imputação mais utilizados devido à sua simplicidade. O código a seguir mostra como funciona o algoritmo 5 da imputação por média.

---

#### Algoritmo 4: IMPUTAÇÃO PELA MEDIA

---

**Entrada:**

1  $n$  = Numero dos valores

**Saída:**  $X_i$  = valor imputado

2 **início**

3 | Identificar a quantidade de numero

4 | Calcular a media

5 |

$$Media = \frac{\sum_{i=1}^n X_i}{n} \quad (4.1)$$

| **retorna** (*Valor da media*)

6 **fim**

---

## 4.2 Imputação pela moda

Usar a moda de um atributo para imputar o valor faltante consiste em substituir os valores faltantes de cada atributo pela moda (no caso de atributos nominais) dos valores do atributo. Essa técnica é bastante usada na prática, mas desconsiderada as diferenças entre as classes e é suscetível a outliers (Em estatística, outlier, valor aberrante ou valor atípico, é uma observação que apresenta um grande afastamento das demais da série (que está "fora" dela), ou que é inconsistente. A existência de outliers implica, tipicamente, em prejuízos a interpretação dos resultados dos testes estatísticos aplicados às amostras).

$$M_0 = L + a \frac{n_{pM_o}}{n_{aM_o} + n_{pM_o}} \quad (4.2)$$

Onde :

$L$  é o limite inferior da classe modal;

$a$  é a amplitude da classe modal;

$naM_o$  é a frequência absoluta da classe à classe modal;

$npM_o$  é a frequência absoluta da classe posterior à classe modal.

## 4.3 Imputação pela regressão linear

(GANDOLFI, 2016) Apresenta que a imputação via regressão incorpora conhecimento de outras variáveis com a ideia de produzir imputações mais inteligentes. A primeira etapa envolve a construção de um modelo a partir dos dados observados. Previsões para os casos incompletos são, então, calculadas de acordo com o modelo ajustado, e servem como substitutos para os dados faltantes.

Utilizamos a análise de regressão linear para definir uma função entre duas ou mais variáveis correlacionadas. A partir de um parâmetro (variável independente) poderemos prever o outro (variável dependente), assumindo que a relação entre as duas variáveis é linear, cuja equação tem a forma genérica:

$$Y = a + bX \quad (4.3)$$

Onde :

$Y$ = Variável dependente que estamos procurando,

$a$ = Intersecção no eixo  $Y$ ,

$b$ = Declividade, ou para cada mudança em  $X$ , quando  $Y$  é alterado,

$X$ = Variável independente.

O objetivo da análise de regressão é encontrar uma função linear que permita: Descrever e compreender a relação entre uma variável dependente e uma ou mais variáveis independentes. Projetar ou estimar uma variável em função de uma ou mais variáveis

independentes; Na regressão linear simples será deduzida e analisada a reta que melhor explica essa relação, tendo previamente definido a variável dependente e a variável independente. A regressão linear múltipla será apresentada através de um exemplo resolvido com a ferramenta de análise de regressão.

O modelo de regressão linear geral é:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{i,p-1} + \varepsilon_i \quad (4.4)$$

e do modelo polinomial é:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i1}^2 + \varepsilon_i \quad (4.5)$$

Onde:

$X_i$  é o vetor de observações das variáveis preditoras para o  $i$  –ésimo caso

$\beta$  é o vetor dos parâmetros

$Y_i$  representa o valor esperado

## 4.4 Imputação pelo k-vizinho mais próximo (knn)

O algoritmo k-vizinho mais próximo (em inglês *k*-Nearest Neighbor - knn) é um dos algoritmos de classificação mais simples e é um dos algoritmos de aprendizado mais utilizados. Sua finalidade é usar um banco de dados no qual os pontos de dados são separados em várias classes para prever a classificação de um novo ponto de amostragem.

Um dos classificadores mais simples e triviais é o classificador rote, que memoriza todos os dados de treinamento e executa a classificação apenas se os atributos do objeto de teste corresponderem exatamente a um dos exemplos de treinamento. Uma desvantagem óbvia dessa abordagem é que muitos registros de teste não serão classificados porque não correspondem exatamente a nenhum dos registros de treinamento.

Segundo (TAN; STEINBACH; KUMAR, 2005), uma abordagem mais sofisticada, a classificação do *k*-vizinho mais próximo (knn), encontra um grupo de *k* objetos no conjunto de treinamento que estão mais próximos do objeto de teste, e baseia a atribuição de um rótulo na predominância de uma classe particular nesta vizinhança. Existem três elementos-chave dessa abordagem: um conjunto de objetos rotulados, por exemplo, um conjunto de registros armazenados, uma métrica de distância ou similaridade para calcular a distância entre objetos e o valor de *k*, o número de vizinhos mais próximos. Para classificar um objeto não rotulado, a distância deste objeto para os objetos rotulados é computada, seus *k* vizinhos mais próximos são identificados e os rótulos de classe desses vizinhos mais

próximos são usados para determinar o rótulo de classe do objeto. O algoritmo 6 a seguir fornece um resumo do método de classificação de vizinho mais próximo.

---

**Algoritmo 5: KNN**


---

**Entrada:**

1  $k$  valor de elemeno **Saída:**  $k$  vizinho  
 2 **início**  
 3     Preparar conjunto de dados de entrada e saída  
 4     Informar o valor de  $k$   
 5     **para** *Cada nova amostra faça*  
 6         Calcular distância para todas as amostras  
 7         Determinar o conjunto das  $k$ 's distâncias mais próximas  
 8         O rótulo com mais representantes no conjunto dos  $k$ 's vizinhos será o  
        escolhido  
 9     **fim**  
 10    **retorna** (*Conjunto de rótulos de classificação*)  
 11 **fim**

---

Para fazer a imputação dos knn , como a amputação da base gera os “NaN” (os valores amputados são substituido pelo “NaN”), para fazer a imputação vamos ter que tirar esses “NaN” por um valor “0” , em seguida o algoritmo de imputação knn se inicia com a substituição dos valores faltantes através da técnica da média para tornar a base de dados completa. Em seguida, é realizado o processo de imputação KNN, ou seja, em n ciclos. Em cada ciclo do knn, são buscadas as k instâncias do conjunto de dados mais próximas a um determinado exemplo que possui valores omissos. As instâncias mais próximas são calculadas através da Distância Euclidiana. No fim de cada ciclo, os valores estimados para os atributos ausentes dessa instância são recalculados e substituídos pelas médias dos valores dos atributos das k (k=3:2:11) instâncias mais próximas encontradas.

## 4.5 Rede Neural

Métodos de aprendizagem profunda (em inglês Deep learning methods) são métodos de aprendizado de máquina que são compostos de múltiplos níveis de operações não-lineares com muitos níveis ocultos dentro das redes neurais. Devido a várias transformações e várias camadas ocultas que capturam os relacionamentos, funções complexas podem ser aprendidas para discriminar as classes de resposta em problemas de classificação. Esta é a principal diferença entre as Redes neurais artificiais (Artificial Neural Networks - ANN) tradicionais e os métodos de aprendizagem profunda. Diversos métodos de aprendizagem profunda foram desenvolvidos e aprimorados recentemente devido aos recursos de computação, como GPUs (Unidades de Processamento Gráfico), que podem manipular múltiplas camadas de redes neurais e construir uma função complexa diz ([GOODFELLOW](#);

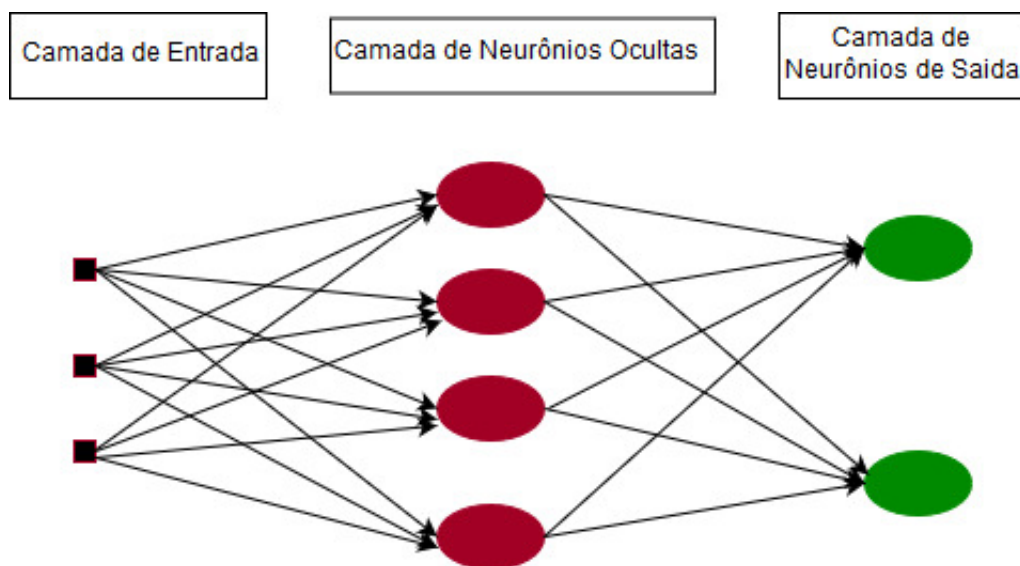
BENGIO, ). Alguns desenvolvimentos recentes de metodologias de aprendizagem profunda e aprimoramento dos métodos existentes incluem redes neurais recorrentes, redes neurais de crença profunda, máquinas Boltzmann restritas, redes Hopfield, autoencodificadores e redes neurais recorrentes. Para os propósitos desta pesquisa, as redes neurais recorrentes sera usado para modelar a imputação e, portanto, é descrito aqui com mais detalhes.

Segundo o livro do (HAYKIN; SIMON, 2001) uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

As redes neurais são também referidas na literatura como neurocomputadores, redes conexionistas, processadores paralelamente distribuídos, etc. A rede neural tira seu poder computacional através de sua estrutura maciçamente paralelamente distribuída e de sua habilidade de aprender e, portanto, de generalizar. Estas duas capacidades de processamento de informação favorece a resolução dos problemas complexos. O uso de redes neurais oferece as seguintes propriedades úteis e capacidades como a não-linearidade, o mapeamento de Entrada-Saída, a adaptabilidade, a resposta a evidências, a informação contextual, a tolerância a falhas, a uniformidade de análise do projeto e a analogia neurobiológico.

Figura 3 – Exemplo de treinamento de uma Rede Neural .



Fonte: Produzido pelo autor.

A unidade fundamental de uma rede neural é o “neurônio”. Análogo a um neurônio biológico, um neurônio artificial é uma unidade computacional que pode receber alguma entrada, processá-lo e se propagar em alguma saída a jusante da rede. A Figura 3 ilustra uma rede neural simples, Essa rede tem três neurônios de entrada, uma camada oculta com quatro neurônios cada e dois neurônio de saída.

Tem vários tipos de redes neurais dentro dos quais podemos citar: Memória de longo prazo, GRU, Redes de Hopfield, Redes neurais recorrentes e outras.

Memória de longo prazo: A Arquitetura de Memória de Longo Prazo Longa consiste de unidades lineares com uma auto conexão com um peso constante de 1.0. Isto permite que um valor (passagem para frente) ou gradiente (passagem para trás) flua para esta unidade auto recorrente a ser preservada e subsequentemente recuperada na etapa de tempo requerida. Com o multiplicador de unidade, a saída ou erro do passo de tempo anterior é o mesmo que o resultado para o próximo intervalo de tempo.

GRU: Uma unidade recorrente (GRU) é parte de um modelo específico de rede neural recorrente que pretende usar conexões através de uma sequência de nós para realizar tarefas de aprendizado de máquina associadas à memória e clustering, por exemplo, no reconhecimento de fala. Unidades recorrentes bloqueadas ajudam a ajustar os pesos de entrada da rede neural para resolver o problema do gradiente de fuga que é um problema comum em redes neurais recorrentes.


Redes de Hopfield: A aprendizagem profunda é um avanço de redes neurais artificiais com múltiplos níveis de representação que são criados por transformações não lineares em cada nível. O aprendizado profundo descobre estruturas complexas e relacionamentos complexos em grandes conjuntos de dados usando algoritmos que permitem o ajuste e o reajuste de recursos que são usados para calcular a representação em uma camada com base na representação das camadas anteriores (LECUN; BENGIO; HINTON, 2015).

## 4.6 Redes neurais recorrentes

Segundo (JONES, 2017) uma rede neural recorrente (em inglês recurrent neural network - RNN) é uma classe de redes neurais que inclui conexões ponderadas dentro de uma camada (em comparação com as redes de feed-forward tradicionais, onde conecta alimentação apenas para camadas subsequentes). Como as RNNs incluem loops, elas podem armazenar informações ao processar novas entradas. Essa memória os torna ideais para tarefas de processamento onde as entradas anteriores devem ser consideradas (como dados da série temporal). Em outros termos, as unidades podem ter conexões com as unidades de camadas anteriores, ou da mesma camada ver Figura 5 a seguir.

Desta maneira, a informação não flui em um sentido único, e a saída da rede

Figura 4 – Uma revisão das redes neurais cíclicas RNN.



Fonte: Blog - Learning Society.

não depende mais apenas da entrada corrente, mas também das entradas anteriores. O efeito prático disto é a existência de memória de curto prazo na rede (NELSON, 2017). O termo “rede neural recorrente” é usado indiscriminadamente para se referir a duas grandes classes de redes com uma estrutura geral similar, onde uma é impulso finito e a outra é impulso infinito. Ambas as classes de redes exibem comportamento dinâmico temporal como diz (MILJANOVIC, 2012). Uma rede recorrente de impulso finito é um gráfico acíclico direcionado que pode ser desenrolado e substituído por uma rede neural estritamente direta, enquanto uma rede recorrente de impulso infinito é um gráfico cíclico direcionado que não pode ser desenrolado.

Tanto o impulso finito quanto as redes recorrentes de impulso infinito podem ter estado armazenado adicional, e o armazenamento pode estar sob controle direto da rede neural. O armazenamento também pode ser substituído por outra rede ou gráfico, se isso incorporar atrasos de tempo ou tiver ciclos de feedback. Esses estados controlados são referidos como estado fechado ou memória fechada, e são parte de memórias de longo prazo de curta duração (LSTMs) e unidades recorrentes bloqueadas (GRU).

As redes neurais recorrentes são usadas em vários casos:

- Dados sequenciais; para fazer uma previsão de um evento a ocorrer ou um evento futuro. Por exemplo queremos fazer uma previsão de tempo as 22h, teremos que pegar as informações das temperaturas anteriores como por exemplo das 8h até as 21h para poder prever o de 22h;

- Prever a próxima ação; por exemplo trabalhando com vídeos, os frames anteriores podem prever qual seria o frame atual, também podemos fazer um previsão do que uma pessoa quer fazer ou quer falar em seguida (SAK; SENIOR; BEAUFAYS, 2014; LI; WU, 2014);

- Processamento de linguagem natural (GRAVES et al., 2009); neste caso podemos

prever qual é a próxima palavra que vai aparecer em um texto, para fazer tradução automática, fazer geração de poema, geração de legendas em vídeos;

-As series temporais (time series); as RNN são específicas para a previsão dos preços de ações na bolsa de valores, previsões de temperatura, crescimento populacional, nível de poluição e vários outros.


Para fazer a imputação dos rnn , como a amputação da base gera os “NaN”, para fazer a imputação vamos ter que tirar esses “NaN” por um valor “0” , em seguida o algoritmo de imputação rnn se inicia com o treinamento dos valores não amputados armazenando os dados através da sua memória. Em seguida, é realizado o processo de imputação rnn, onde a cada valor de “0” encontrado vai ser substituído por um novo valor que é o valor da imputação encontrado pela rede. No nosso caso vamos usar 200 épocas (número de iteração para que a rede possa treinar o suficiente possível para responder a imputação) para que o treinamento seja o mais elaborado. Pode ser usada outras épocas, mas nós definimos como padrão 200 para todas as taxas de imputação. Para a execução da rede, a retropropagação que é um algoritmo de treinamento, controla o sistema a longo prazo que no nosso caso são as épocas.

## 4.7 Retropropagação

A Retro propagação (em inglês Backpropagation ) é uma ferramenta muito poderosa, com aplicações para reconhecimento de padrões, modelagem dinâmica, análise de sensibilidade e controle de sistemas ao longo do tempo, entre outros. Pode ser aplicado a redes neurais, a modelos econométricos, a estruturas lógicas difusas, a modelos de dinâmica de fluidos e a praticamente qualquer sistema construído a partir de subsistemas ou cálculos elementares. A única restrição séria é que os subsistemas elementares devem ser representados por funções conhecidas pelo usuário, funções que são tanto contínuas quanto diferenciáveis (isto é, possuem derivadas). Por exemplo ([WERBOS, 1974](#)) afirma na sua dissertação que, a primeira aplicação prática da retro propagação foi para estimar um modelo dinâmico para prever o nacionalismo e as comunicações sociais em 1974

Um problema “não-linearmente separável” é aquele onde não poderemos separar duas classes distintas no eixo cartesiano bidimensional apenas traçando uma reta. Na 5 temos um exemplo claro disso. Observamos que é impossível separar o padrão “\*” do padrão “.” Apenas traçando uma reta. Quer dizer que se você tiver como meta identificar se aquele objeto é estrela ou ponto e em algum momento esses padrões apresentam a característica acima, os algoritmos que não resolvem problemas desse tipo não serão capazes de distinguir estrela de ponto.

Figura 5 – Problema não linearmente separável .



Fonte: Produzido pelo autor.

## 4.8 Retropropagação através do tempo

O algoritmo de Retro propagação através do tempo (em Inglês Backpropagation Through Time - BPTT) é uma extensão natural do retro propagação padrão (já visto em no item 5.2) que executa gradiente descendente em uma rede completa desdobrada. Se uma sequência de treinamento de rede começa no tempo  $t_0$  e termina no tempo  $t_1$ , a função de custo total é simplesmente a soma ao longo do tempo da função de erro padrão  $E_{sse/ce}(t)$  em cada etapa de tempo:

$$E_{total}(t_0, t_1) = \sum_{t=t_0}^{t_1} E_{sse/ce}(t) \quad (4.6)$$

Como explica a Figura 6


e as atualizações de peso de gradiente descendente têm contribuições de cada etapa de tempo.

$$\Delta w_{ij} = -\eta \frac{\partial E_{total}(t_0, t_1)}{\partial w_{ij}} = -\eta \sum_{t=t_0}^{t_1} \frac{\partial E_{sse/ce}(t)}{\partial w_{ij}} \quad (4.7)$$

Como explica a Figura 7

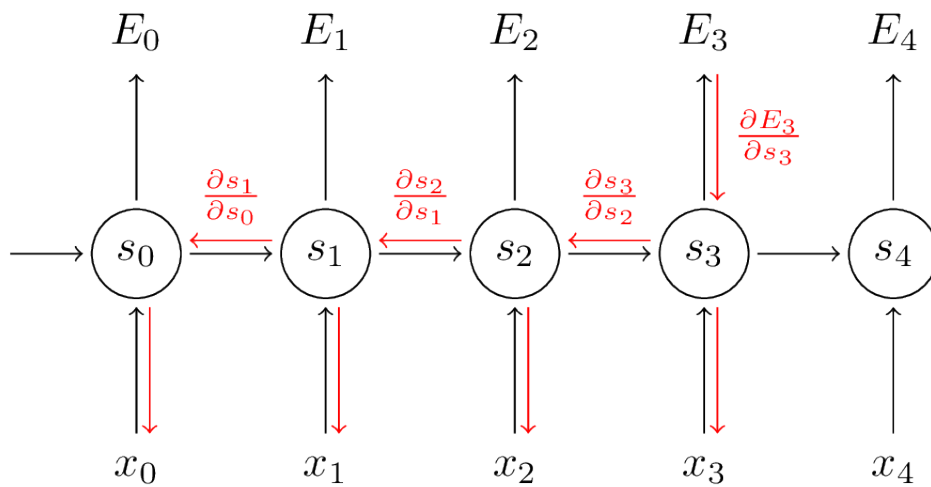
As derivadas parciais constituintes  $\partial E_{sse/ce}/\partial w_{ij}$  agora têm contribuições das múltiplas instâncias de cada peso  $w_{ij} \in (W_{IH}, W_{HH})$ , e dependem das entradas e ativações das unidades ocultas nos passos de tempo anteriores. Os erros agora precisam ser propagados de volta ao longo do tempo, bem como através da rede.

Figura 6 – BPTT sem gradiente.



Fonte: A implementação RNN de caracteres mínimos de Andrej Karpathy.

Figura 7 – BPTT com gradiente.



Fonte: A implementação RNN de caracteres mínimos de Andrej Karpathy.


## 5 Metodologia de testes

Para os testes foi utilizada a framework que compreende das etapas de aquisição de dados, definição de parâmetros, compressão de dados, validação, extração de características, detecção de danos, amputação de dados, imputação de dados e análise de resultados.

### 5.1 Aquisição de dados

A ponte Z24 foi construída em 1961 com a intenção de ligar as aldeias de Utzenstorf e Koppigen na Suíça. Essa ponte é uma estrutura pós-tensionada de vigas de caixa de concreto. A ponte possui um vão principal no meio de 30 metros e dois vãos laterais de 14 metros cada, como visto na Figura 8.

Figura 8 – Z-24 Esquema de ponte (direito) e imagem (canto superior esquerda), bem como um cenário de dano introduzido pela falha da cabeça de âncora (canto inferior esquerda).



Por motivos que não tinham relação com a qualidade ou estrutura da ponte, ela precisou ser demolida para dar espaço a uma ponte maior. Entretanto antes de demolir ela, foram feitos testes para o projeto *System Identification to Monitor Civil Engineering* (SIMCES) para extrair dados que pudessem ser usados para testes de detecção de danos (PEETERS; ROECK, 2000).

Nesses testes foram implantados 49 sensores que coletaram dados de vibração e ambientais. De hora em hora durante aproximadamente 10 meses entre 1997 e 1998 foram coletados dados dos sensores, gerando um volume de 3932 medições (235 dias) (FIGUEIREDO; MOLDOVAN; MARQUES, 2013).

Por volta do último mês, foram introduzidas condições de danos propositalmente para adquirir dados dos sensores em cenários com danos (PEETERS; ROECK, 2000). Sendo assim a base de dados tem um longo período de medições sem danos e um período com danos, possibilitando fazer testes e validações com os dados gerados.

Testes de dano progressivo foram realizados no período de um mês (de 4 de agosto a 10 de setembro de 1998) antes da demolição da ponte para provar que dano realístico tem uma influência mensurável na dinâmica da ponte, (PEETERS; ROECK, 2000) conforme resumido na Tabela 1. Observe que o sistema de monitoramento contínuo ainda estava em execução durante os testes de danos progressivos, o que permite validar o sistema SHM para detectar danos cumulativos no monitoramento de longo prazo.


Tabela 1 – O desempenho da classificação (erros tipo I e II) e o número de componentes para cada algoritmo.

Execução	EM-GMM			GA-EM-GMM		
	Erro		Componentes	Erro		Componentes
	Tipo I	Tipo II		Tipo I	Tipo II	
1	63	127	6	93	14	7
2	77	18	7	93	14	7
3	62	70	6	103	11	7
4	67	19	7	94	14	7
5	103	11	7	93	14	7
6	118	11	7	94	14	7
7	103	11	7	95	11	7
8	103	11	7	112	11	7
9	77	18	7	93	14	7
10	24	86	6	93	14	7
11	86	13	8	96	11	7
12	68	18	7	97	12	7
13	83	13	8	87	14	7
14	105	11	7	93	14	7
15	68	51	6	95	12	7
16	67	37	6	93	14	7
17	119	11	7	95	12	7
18	103	11	7	93	14	7
19	24	110	6	93	14	7
20	77	18	7	87	14	7

Neste caso, as frequências naturais do Z-24 Bridge são usadas como recursos sensíveis a danos. Eles foram estimados usando um método de identificação de subespaço estocástico baseado em referência em séries temporais a partir dos acelerômetros (PEETERS; ROECK, 1999). As primeiras quatro frequências naturais estimadas de hora em hora de 11 de novembro de 1997 a 10 de setembro de 1998, com um total de 3932 observações, são

destacadas na Figura 9. As primeiras 3470 observações correspondem aos vetores de características sensíveis a danos extraídos dentro da condição estrutural não danificada sob operacional e influências ambientais. As últimas 462 observações correspondem ao período de teste progressivo de dano, que é destacado, especialmente na segunda frequência, por uma clara queda na magnitude da frequência.

Figura 9 – Dados Originais das frequências da base Z24.



## 5.2 Definição de Parâmetros

Para poder simular o que aconteceria no caso de falhas no sensor, ocasionando então em valor ausente, foi realizado um processo completamente aleatório de remoção dos dados. A função implementada em *Matlab* que foi desenvolvida nesse estudo para simular a ocorrência de dados faltantes aceita como parâmetro a porcentagem de dados que deve ser removida. Dessa maneira, nesse trabalho, as porcentagens de perdas de dados utilizadas foram: 10%, 20%, 30%, 60%, e 90%.

Para possuir um *baseline* de comparação para os métodos de imputação analisados, realizou-se também uma amputação dos valores ausentes, ou seja, as observações que

foram escolhidas aleatoriamente como valores ausentes foram excluídas da análise. A partir desse novo conjunto de dados com uma determinada porcentagem de dados removidos, foi realizado uma análise através de técnicas de detecção de danos para determinar o comportamento dos algoritmos de detecção de danos diante da amputação dos dados. No capítulo de resultados, também analisaremos o impacto das diferentes taxas de dados faltantes na sensibilidade das features extraídas.

### 5.3 Extração de características

Nessa etapa foi extraído as características relevantes dos dados obtidos durante os 10 meses de testes e monitoramento da Z24. Conforme mencionado antes, foram utilizados somente os dados do sensor 5 para esse propósito. Outra decisão foi utilizar os dados obtidos durante as medições de 12h, pois estão mais sucintos a variabilidade de temperatura, portanto são um desafio maior de classificar. Não foi, porém, utilizado os dados brutos dos sensores. Para extrair características relevantes desse sinal foi utilizado um processo de decomposição do sinal no domínio da frequência.

### 5.4 Amputação e imputação de danos

A amputação é feita tirando 10%, 20%, 30%, 60% e 90% dos valores da base inteira (Base Z24) de maneira artificial. Após ser feita a preparação dos dados, deve-se utilizar diferentes algoritmos de imputação nas bases de dados com valores faltantes para que os resultados gerados possam ser comparados. As bases de dados com 10%, 20%, 30%, 60% e 90% de seus valores faltantes passaram pelos processos de imputação pelo knn e imputação pela rede neural recorrente. Com isso, as bases de dados ficaram completas. Os algoritmos de imputação foram executados uma vez para cada base de dados que tinha valores faltantes. O knn foi aplicado em um único ciclo com  $k = 3$ , ou seja, para cada instância com valores ausentes foram encontrados três vizinhos mais próximos. A rnn foi também aplicado uma vez com 200 épocas (número de iteração para que a rede possa treinar o suficiente possível para responder a imputação).

### 5.5 Critérios tradicionais de avaliação

O erro quadrático médio (MSE) avalia a qualidade de um estimador (ou seja, uma função matemática mapeando uma amostra de dados para uma estimativa de um parâmetro da população da qual os dados são amostrados) ou um preditor (isto é, uma função mapeando entradas arbitrárias para uma amostra de dados dos valores de alguma variável aleatória), e é utilizado nesse estudo como um critério de avaliação das predições,

utilizando os valores das variáveis que foram imputadas associadas aos valores reais da observação e a magnitude da variância estimada. E é dado por :

$$MSE = \frac{\sum_{i=1}^n (X_i^{obs} - X_i^{imputado})^2}{n} \quad (5.1)$$

Outra quantidade que calculamos é o Root Mean Squared Error (RMSE). É apenas a raiz quadrada do erro quadrático médio. Essa é provavelmente a estatística mais facilmente interpretada, pois possui as mesmas unidades que a quantidade plotada no eixo vertical.

O RMSE é diretamente interpretável em termos de unidades de medida e, portanto, é uma melhor medida de adequação do que um coeficiente de correlação. É dado por:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i^{obs} - X_i^{imputado})^2}{n}} \quad (5.2)$$

O MSE e a RMSE é calculado para cada porcentagem de dados faltantes em conjunto com uma das técnicas de imputação dos dados. Para cada frequência foi calculado a média entre os resultados das simulações para alcançar o resultado final.

O MAE é a média da diferença absoluta entre os valores previstos e o valor observado. O MAE é uma pontuação linear, o que significa que todas as diferenças individuais são ponderadas igualmente na média. Por exemplo, a diferença entre 10 e 0 será o dobro da diferença entre 5 e 0. No entanto, o mesmo não é verdade para o RMSE. Matematicamente, é calculado usando esta fórmula:

$$MAE = \frac{1}{n} \sum_{j=1}^n |Y_j - \hat{Y}_j| \quad (5.3)$$

O R-quadrado é uma medida estatística de quão próximos os dados estão da linha de regressão ajustada. É também conhecido como o coeficiente de determinação, ou o coeficiente de determinação múltipla para regressão múltipla. 0% indica que o modelo não explica nada da variabilidade dos dados de resposta em torno de sua média. R-quadrado é freqüentemente usado para fins explicativos e explica como a (s) variável (s) independente (s) selecionada (s) explicam a variabilidade em sua (s) variável (s) dependente (s). Matematicamente, o R-quadrado é dado por:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (5.4)$$

O numerador é MSE (média dos quadrados dos residuais) e o denominador é a variância nos valores Y. Quanto mais alto o MSE, menor o R-quadrado e mais pobre é o modelo.

### 5.5.1 Mahalanobis squared-distance

Alguns autores como (WORDEN et al., 2007) utilizaram o Mahalanobis squared-distance (MSD) como uma medida de distância para a detecção de dados atípicos de estatística multivariada

A distância de Mahalanobis difere da distância euclidiana porque leva em consideração a correlação entre as variáveis e não depende da escala das características. No entanto, este modelo assume que os dados seguem uma distribuição gaussiana multivariada única, ou seja, os dados podem ser modelados por apenas um cluster gaussiano. Considerando a matriz de dados de treinamento  $X$ , estima-se um vetor de atributos médios  $\mu$  e uma matriz de covariância. No contexto da normalização dos dados, o vetor médio e a matriz de covariância devem codificar todas as variações normais representadas pelos dados da linha de base. Assim, para um dado de teste  $Z_l$ , o MSD é usado como um procedimento de análise outlier padrão, fornecendo DIs por (??), e é dada pela fórmula:

$$DI(l) = (Z_l - \mu) \sum^{-1} (Z_l - \mu)^T \quad (5.5)$$

A principal suposição é que, se um vetor de característica de teste é obtido de dados coletados no sistema danificado que incluem variabilidade operacional e ambiental, semelhante aos dados de treinamento, esse vetor estará mais longe dos vetores de característica médios correspondentes à condição não danificada como quantificada pelo MSD.

## 6 Resultados

Aqui apresentaremos os resultados obtidos através dos testes mencionados anteriormente e faremos uma análise dos mesmos. Primeiramente é mostrada a sensibilidade do sinal à diferentes percentuais de perda de dados. Em seguida, a comparação dos resultados dos métodos de imputação é realizada através da análise dos critérios de MSE, RMSE, MAE e  $R^2$ . Por fim vamos realizar a avaliação desses resultados.

### 6.1 Determinação de características sensíveis a danos

Uma identificação de parâmetro modal local foi executada para cada um dos 3932 conjuntos de dados de aceleração registrados por hora. Como as forças ambientais atuantes na ponte não puderam ser medidas e nenhuma excitação artificial foi aplicada, utilizou-se uma técnica de identificação do sistema somente de saída, ou seja, a identificação do subespaço estocástico baseado em referência, (P.R.; JACKSON; SOMERS, 2005). Para identificar modos fracamente excitados, a modelagem excessiva foi empregada em combinação com o diagrama de estabilização técnica (REYNDERS; HOUBRECHTS; ROECK, 2012).

A seleção das características modais do diagrama de estabilização foi automatizado de maneira ad hoc, resultando em quatro modos para os quais as características modais puderam ser identificadas com precisão suficiente: um modo de flexão vertical em torno de 4 Hz, um modo de flexão lateral em torno de 5 Hz e dois modos combinando flexão vertical e torção em torno de 10 e 11 Hz. As razões de amortecimento foram consideradas insensíveis às mudanças ambientais e aos danos.

Formas de modo detalhado não estão disponíveis devido ao número limitado de acelerômetros usados durante o período de monitoramento. Portanto, apenas as quatro frequências próprias são tomadas aqui como recursos sensíveis a danos, como visto na Figura 9.

### 6.2 Comportamento do sinal à perda de dados

Para fazer este estudo vamos avaliar o impacto de diferentes taxas de dados faltantes na sensibilidade do sinal, a fim de analisar em qual percentual o sinal começa a perder suas características. Dessa maneira, fazemos as análises a partir dos percentuais de valores ausente de 10%, 20%, 30%, 60% e 90% como ilustrado nas figuras a seguir.

### 6.2.1 Comportamento do sinal como o knn

Nas figuras estamos plotando as curvas em azul são os dados originais sem amputação e as curvas em preto possui os dados imputados.

Para entender melhor, vamos comparar a cada percentual a imputação para ver como e quanto eficiente é a imputação mesmo com as amputações aleatórios.

Na Figura 10, é possível analisarmos a comparação das frequências com as diferentes taxas de dados imputados. Como podemos ver na imagem, as curvas perderam de forma significativa das suas características já a partir de 10% dos valores imputados. O comportamento das curvas obtidas após a imputação dos dados não se assemelha mais ao comportamento das curvas originais.

Dessa maneira, podemos verificar que para o processo de extração de features para SHM, o sinal obtido da ponte Z-24 aparenta ser bastante sensível à perda de dados. Outros testes com porcentagens mais altas também foram realizados, no entanto, como foi verificado que em 10% a curva já perde suas características originais, o nosso estudo se limitou a mostrar os gráficos de 20%, 30%, 60% e 90%.

Podemos perceber que quanto maior for a amputação, maior é a perda em relação a base original com a imputação do knn.

### 6.2.2 Comportamento do sinal com a rede neural recorrente

Na figura 12 iremos ver a imputação da base pela rede neural recorrente; e para entender melhor o comportamento da rede, vamos imputar os dados com 10%, 20%, 30%, 60% e 90% todos com a mesma temporadas. As curvas em azul são os dados originais sem amputação e as curvas em preto possui os dados imputados.

Com isso podemos constatar que quanto mais a temporada for alta, mais a rede consegue imputar melhor. A imputação de 10% com só uma temporada, deu para perceber que a rede simplesmente repete os mesmos valores o tempo inteiro, então a imputação foi péssima; o mesmo com a imputação de 20% com 10 temporadas. A imputação com 90% deu uma melhorada pois a temporada dele foi até 200, o que deu para ele treinar mais e dar um bom resultado. Dessa maneira, podemos verificar que para o processo de extração de features para SHM, o sinal obtido da ponte Z-24 aparenta ser bastante sensível à perda de dados.

## 6.3 Comparação dos métodos de imputação de dados

Para fazer a análise da sensibilidade do processo de extração das features, podemos prosseguir para a comparação dos métodos de imputação, que possuem como objetivo evitar os efeitos negativos causados pela amputação dos dados. Afim de confirmar os resultados das imputações, a comparação se inicia pela análise dos erros do tipo I e do tipo II do processo de extração de features para cada método; depois é feita a comparação através do MSE, MAE e  $R^2$  critérios tradicionais da literatura de imputação de dados.

### 6.3.1 MSE, MAE e $R^2$

As Tabelas 2, 3 e 4 mostra o MSE global, MAE global e  $R^2$  global obtido com cada método de imputação para cada percentual de dados faltantes analisado. Os resultados obtidos com esses critérios mostram que a rnn possui os melhores resultados com os critérios tradicionais de avaliação do MSE, enquanto com o MAE o knn se tem um melhor desempenho e obtivermos um empate na parte do R-quadrado.; igualmente com as tabelas 5, 6, 7, 8 e 19 com as mesma técnicas mas local. Global quer dizer da base inteira e local por cada frequência.

Tabela 2 – Resultados da tecnica de MSE

MSE	knn	rnn 200
10%	0.0094204	0.0011347
20%	0.0091502	0.0018854
30%	0.0084084	0.0027944
60%	0.0088463	0.0066694
90%	0.010816	0.0095786

Tabela 3 – Resultados da tecnica de MAE

MAE	knn	rnn 200
10%	0.062387	0.076262
20%	0.06181	0.070242
30%	0.059403	0.07337
60%	0.060859	0.084244
90%	0.068206	0.089666

### 6.3.2 Erro do tipo I e tipo II

Foi avaliado, por algoritmo de compressão a quantidade média de erros Tipo I e Tipo II para cada algoritmo de detecção de dano, como podemos ver na Figura 14 a seguir:

Para quantificar o desempenho dos classificadores para um dado limiar, a Figura 14 mostra o indicador de dano, juntamente com um limite definido com base no valor de

Tabela 4 – Resultados da tecnica de  $R^2$ 

$R^2$	knn	rnn 200
10%	0.99982	0.99888
20%	0.99979	0.99878
30%	0.99976	0.9987
60%	0.99947	0.99897
90%	0.99879	0.99837

Tabela 5 – Resultados das tecnicas a 10% de imputação

*	F1	F1	F2	F2	F3	F3	F4	F4
*	knn	rnn	knn	rnn	knn	rnn	knn	rnn
MSE	0.00059769	0.0012555	0.0018716	0.01306	0.011956	0.0097094	0.023256	0.023839
MAE	0.016398	0.0012555	0.03235	0.01306	0.083228	0.0097094	0.11757	0.023839
$R^2$	0.94364	0.82182	0.92795	0.53313	0.82497	0.79282	0.75615	0.76455

Tabela 6 – Resultados das tecnicas a 20% de imputação

*	F1	F1	F2	F2	F3	F3	F4	F4
*	knn	rnn	knn	rnn	knn	rnn	knn	rnn
MSE	0.00054649	0.0010499	0.0019465	0.010818	0.010048	0.0095144	0.021093	0.019438
MAE	0.016618	0.0010499	0.033077	0.010818	0.076093	0.0095144	0.11182	0.019438
$R^2$	0.94485	0.84180	0.91964	0.54313	0.84846	0.77282	0.76559	0.77455

imputação de 30% dos dados de treinamento. Os erros Tipo I (indicação de dano falso positivo) e Tipo II (indicação de dano falso negativo) são uma maneira comum de relatar o desempenho de uma classificação binária. Esta técnica reconhece que uma classificação falso-positiva pode ter consequências diferentes das falsas e negativas. A Tabela 10 resume o número de erros Tipo I e Tipo II para cada algoritmo. Em uma análise geral, a tabela mostra um trade-off claro entre os erros Tipo I e Tipo II, com os algoritmos baseados em knn e rnn.

No entanto, todos os algoritmos têm um bom desempenho quando comparados nesses conjuntos de dados padrão (baseline) com a porcentagem de erros totais (erros Tipo I e Tipo II) variando entre 383 e 453 do número de testes, enquanto o baseline está a 410; o que pode ser considerado um bom resultado.

Portanto, para esses conjuntos de dados específicos, pode-se concluir que esses

Tabela 7 – Resultados das tecnicas a 30% de imputação

*	F1	F1	F2	F2	F3	F3	F4	F4
*	knn	rnn	knn	rnn	knn	rnn	knn	rnn
MSE	0.00054649	0.0012843	0.0019465	0.01162	0.010048	0.010795	0.021093	0.020106
MAE	0.016618	0.0012843	0.033077	0.01162	0.076093	0.010795	0.11182	0.020106
$R^2$	0.94485	0.87180	0.91964	0.57313	0.84846	0.78282	0.76559	0.79455

Tabela 8 – Resultados das técnicas a 60% de imputação

*	F1	F1	F2	F2	F3	F3	F4	F4
*	knn	rnn	knn	rnn	knn	rnn	knn	rnn
MSE	0.00068208	0.0022253	0.0021169	0.013565	0.010417	0.016411	0.02217	0.026628
MAE	0.018154	0.0022253	0.034001	0.013565	0.078006	0.016411	0.11327	0.026628
R <sup>2</sup>	0.93881	0.86090	0.92091	0.61313	0.85759	0.78282	0.77452	0.80455

Tabela 9 – Resultados das técnicas a 90% de imputação


*	F1	F1	F2	F2	F3	F3	F4	F4
*	knn	rnn	knn	rnn	knn	rnn	knn	rnn
MSE	0.0012769	0.0022661	0.0034052	0.014596	0.013879	0.018172	0.013879	0.029899
MAE	0.023547	0.0022661	0.042124	0.014596	0.087017	0.018172	0.12013	0.029899
R <sup>2</sup>	0.8835	0.85182	0.87394	0.53313	0.80659	0.79282	0.74639	0.76055

dois algoritmos baseados em knn e rnn são mais apropriados quando se deseja minimizar as indicações falso-positivas de danos, com problemas econômicos e de confiabilidade impulsionando o SHM.


Tabela 10 – Resultados do erro do tipo I e II de R<sup>2</sup>

30%	Tipo I	Tipo II	Total
Baseline	305	105	410
knn	280	103	383
rnn	321	132	453


Figura 10 – Imputação por knn das frequências por cada taxa definido da base Z24.



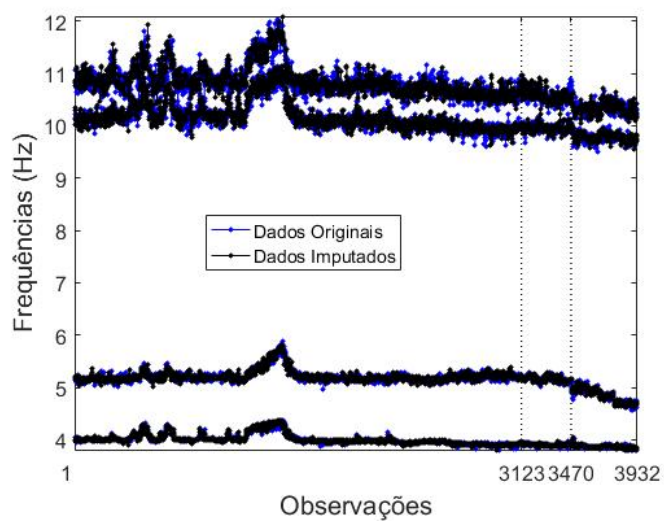
(a) knn10




(b) knn20



(c) knn30



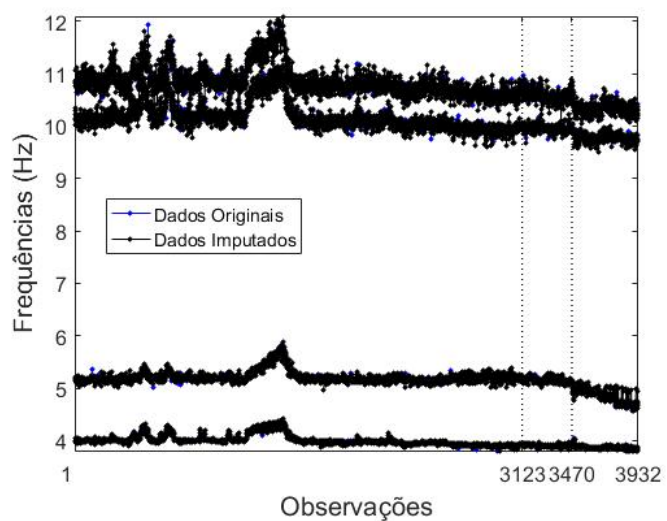
(a) knn60




(b) knn90

Fonte: Produzido pelo autor.


Figura 12 – Imputação por rnm das frequências por cada taxa definido da base Z24.




(a) rnm10




(b) rnm20



(c) rnm30




(a) rnm60



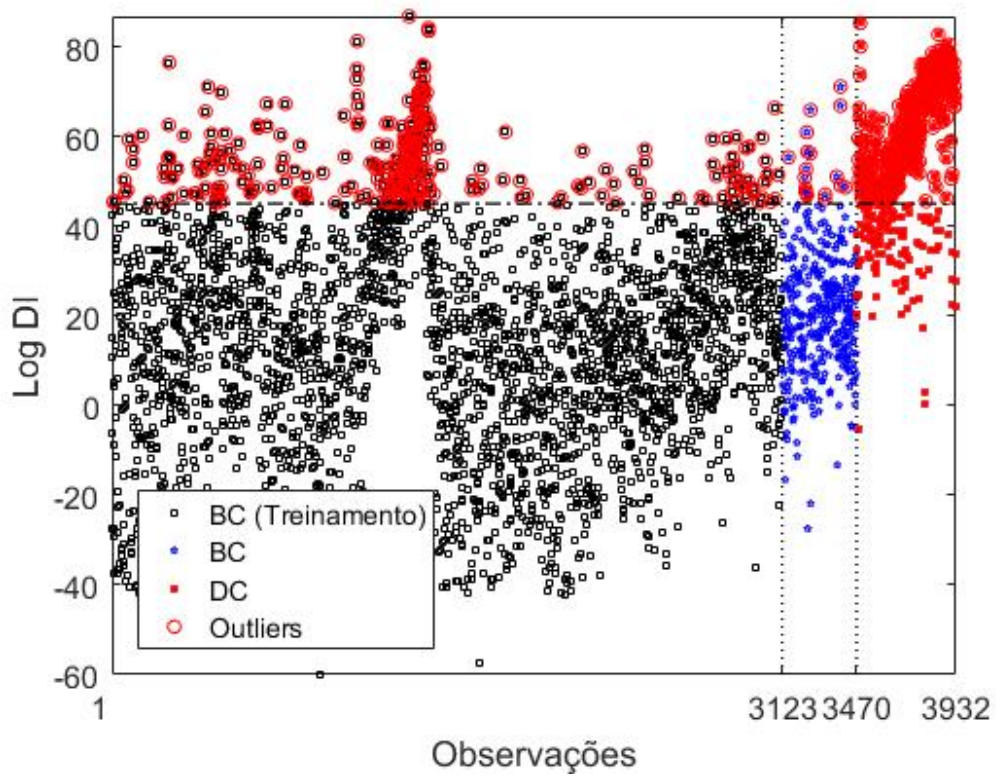
(b) rnm 90

Fonte: Produzido pelo autor.

Figura 14 – Indicadores de danos por knn e por rnn dos valores imputados da base Z24.



(a) knn



(b) rnn

Fonte: Produzido pelo autor.

## 7 Considerações Finais

Este trabalho apresentou metodologias para imputação de dados, especificamente com os algoritmos de knn e de rede neural recorrente, que se mostraram boas alternativas para o tratamento de dados faltantes. Os ajustes do modelo logístico com valores obtidos por imputação via algoritmo de rede neural recorrente, em geral, foram melhores do que as estimativas mantendo os valores perdidos. Mesmo com o número de época ficando em 200 podemos perceber que a rede se desempenhou bem em fazer o treinamento e por seguir uma imputação aceitável, e quando maior for a amputação mais medíocre fica a imputação tanto da rnn quanto da knn. Até os 10% de imputação não havia muito dando mais passando desse limite percebemos que a imputação não fica mais como desejado. Com o knn, a baixa variabilidade da matriz dos valores de altura das cultivares em relação à média dos valores imputados, indicando uma boa precisão do processo de imputação. Comparando os erro do tipo I e II, todos os algoritmos têm um bom desempenho quando comparados nesses conjuntos de baseline com a porcentagem de erros totais (erros Tipo I e Tipo II) variando entre 383 e 453 do número de testes, enquanto o baseline está a 410; o que pode ser considerado um bom resultado. Portanto, para esses conjuntos de dados específicos, podemos afirmar que esses dois algoritmos baseados em knn e rnn são mais apropriados quando se deseja minimizar as indicações falso-positivas de danos, com problemas econômicos e de confiabilidade impulsionando ao SHM. No que se ver dos critérios tradicionais de avaliação, os MSE, MAE e o  $R^2$  podemos afirmar que a rede deu uma maior taxa de confiabilidade analisando as percentagens obtido após da imputados via os dois métodos.

### 7.1 Trabalhos Futuros

Para que o desempenho dos métodos de imputação apresentados neste trabalho seja melhor avaliado considera-se importante:

- Em estudos sobre o algoritmo de rede neural recorrente, incluir mais variáveis com dados faltantes e verificar o comportamento desta técnica em muitas proporções distintas de dado faltante;
- Efetuar avaliações do método de rede neural recorrente em bases dados que apresentem casos outliers ou dados desbalanceados.

Outro ponto de investigação é a adição de diferentes técnicas de imputação de dados. Como a área de SHM está em constante desenvolvimento e novas técnicas relacionadas a

---

esta área surgem constantemente, a utilização do método de avaliação proposto pode se tornar uma ferramenta poderosa para teste e validação de novos algoritmos de amputação de dados e imputação de dados em SHM. Para facilitar esse estudo comparativo, um outro projeto que pode surgir desse trabalho é implementar o framework de maneira genérica que seja facilmente estendido para outras técnicas e bases de dados, automatizando o processo de obter essas análises.

# Referências

- BALABAN, E. et al. Modeling, detection, and disambiguation of sensor faults for aerospace applications. *Sensors Journal, IEEE*, v. 9, p. 1907 – 1917, 01 2010. Citado na página 12.
- BATISTA, G.; MONARD, M. An analysis of four missing data treatment methods for supervised learning. *Applied Artificial Intelligence*, v. 17, n. 43, p. 519–533, May 2003. Citado 3 vezes nas páginas 22, 23 e 27.
- BERTINI, J. R.; NICOLETTI, M. do C.; ZHAO, L. Imputation of missing data supported by complete p-partite attribute-based decision graphs. In: *2014 International Joint Conference on Neural Networks (IJCNN)*. [S.l.: s.n.], 2014. p. 1100–1106. ISSN 2161-4407. Citado na página 13.
- BROWNSTONE, D.; VALLETTA, R. The bootstrap and multiple imputations: Harnessing increased computing power for improved statistical tests. *Journal of Economic Perspectives*, v. 29, n. 4, p. 231 – 252, 2001. Nenhuma citação no texto.
- CHANG, Z. P.; LI, Y. W.; FATIMA, N. A theoretical survey on mahalanobis-taguchi system. *Measurement*, 2018. Nenhuma citação no texto.
- CHEN, Z. et al. A novel distribution regression approach for data loss compensation in structural health monitoring. *Structural Health Monitoring*, v. 17, n. 6, p. 1473–1490, 2018. Citado na página 12.
- COSTA, E. A. F. Aplicação de técnicas de imputação de dados a shm. *UNIVERSIDADE FEDERAL DO PARÁ*, p. 94, August 2018. Citado na página 15.
- CZARNECKI, H. S. C. R. F. F. M. H. J. J. *A Review of Structural Health Monitoring Literature: 1996-2001*. [S.l.: s.n.], 2004. Citado 3 vezes nas páginas 18, 19 e 20.
- DANIN, L. A. M. R. Proposta de método de avaliação para framework de compressão de dados e detecção em monitoramento de integridade estrutural. *Trabalho de Conclusão de Curso (Baicharelado em Ciência da Computação)*, Universidade Federal do Pará, p. 149–171, December 2016. Nenhuma citação no texto.
- DAWSON, B. Vibration condition monitoring techniques for rotating machinery. *The Shock and Vibration Digest*, v. 8, n. 12, 1976. Citado na página 17.
- EIBEN, A. E.; SMITH, J. From evolutionary computation to the evolution of things. *Nature*, Nature Publishing Group, a division of Macmillan Publishers Limited. All Rights Reserved, May 2015. Citado na página 14.
- FARRAR, C. R.; DOEBLING, S. W.; NIX, D. A. Vibration-based structural damage identification. *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences, The Royal Society.*, v. 359, n. 1778, p. 131–149, 2001. Citado na página 17.

- FARRAR, C. R.; WORDEN, K. Structural health monitoring: A machine learning perspective. *Hoboken NJ, United States: John Wiley & Sons, Inc*, p. 656, December 2013. Citado 3 vezes nas páginas 11, 18 e 20.
- FIGUEIREDO, E.; MOLDOVAN, I.; MARQUES, M. B. Condition assessment of bridges: Past, present and future. a complementary approach. *Católica Editora*, 2013. Citado 4 vezes nas páginas 11, 12, 18 e 37.
- FIGUEIREDO, E. J. F. e. a. Damage identification in civil engineering infrastructure under operational and environmental conditions. *Sage Publications Sage UK: London, England*, 2010. Citado na página 18.
- GANDOLFI, M. *Imputação Múltipla via Algoritmo Mice e Método imld*. Tese (Mestre em Bioestatística) — Universidade Estadual de Maringá – UEM, Maringá-PR, 2016. Citado na página 28.
- GARCIARENA, U.; SANTANA, R. An extensive analysis of the interaction between missing data types, imputation methods, and supervised classifiers. *journals elsevier & An International Journal*, v. 89, n. 13, p. 52–65, December 2017. Citado na página 21.
- GOODFELLOW, I.; BENGIO, A. Y. *Dicourville deep learning mit press*. *Cambridge MA*. Citado na página 31.
- GRAVES, A. et al. A novel connectionist system for improved unconstrained handwriting recognition. *IEEE*, n. 15, 2009. Citado na página 33.
- GRZYMALA-BUSSE, J. W.; HU, M. A comparison of several approaches to missing attribute values in data mining. In: *Revised Papers from the Second International Conference on Rough Sets and Current Trends in Computing*. Berlin, Heidelberg: Springer-Verlag, 2001. p. 378–385. ISBN 3-540-43074-1. Citado na página 13.
- HAYKIN; SIMON. *Redes neurais: princípios e prática*. [S.l.]: Bookman, 2001. Citado na página 31.
- HERNANDEZ-PEREIRA, E.; ALVAREZ-ESTÉVEZ, D.; MORET-BONILLO, V. Automatic classification of respiratory patterns involving missing data imputation techniques. *Biosystems Engineering*, v. 138, n. 11, p. 65–76, 2015. Citado 2 vezes nas páginas 22 e 23.
- HRUSCHKA, E. R. et al. On the influence of imputation in classification: practical issues. *Journal of Experimental & Theoretical Artificial Intelligence*, Taylor & Francis, v. 21, n. 1, p. 43–58, 2009. Citado na página 14.
- HRUSCHKA, J. E. R.; HRUSCHKA, E. R.; EBECKEN, N. F. Bayesian networks for imputation in classification problems. *Journal of Intelligent Information Systems*, v. 29, n. 21, p. 129–141, Dezembro 2001. Citado na página 27.
- HU, W.-H. et al. Comparison of different statistical approaches for removing environmental/operational effects for massive data continuously collected from footbridges. *Structural Control and Health Monitoring*, v. 24, n. 8, p. e1955, August 2017. Citado na página 11.

- JM, J. et al. Missing data imputation using statistical and machine learning methods in a real breast cancer problem. *Artificial Intelligence in Medicine*, US National Library of Medicine National Institutes of Health, July 2010. Citado na página 12.
- JONES, M. T. Um mergulho profundo nas redes neurais recorrentes. *iMasters*, v. 03, p. 128, Setembro 2017. Citado na página 32.
- JW, G. Missing data analysis: making it work in the real world. *US National Library of Medicine National Institutes of Health Search database*, 2009. Citado na página 14.
- LAENCINA, P. G.; SANCHO-GÓMEZ, J. L.; FIGUEIRAS-VIDAL, A. R. Pattern classification with missing data: A review. *Neural Computing and Applications*, v. 19, p. 263–282, 03 2010. Citado na página 14.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature* *x*, v. 521, n. 8, p. 436–444, 2015. Citado na página 32.
- LI, X.; WU, X. Constructing long short-term memory based deep recurrent neural networks for large vocabulary speech recognition. *arXiv:1410.4281*, Setembro 2014. Citado na página 33.
- LIMA, M. et al. A framework for data compression and damage detection in structural health monitoring applied on a laboratory three-story structure. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, v. 8, p. 129–143, July 2016. Citado na página 12.
- LITTLE, R. J.; RUBIN, D. B. Statistical analysis with missing data. *IEEE Transactions on Software Engineering*, John Wiley & Sons, v. 333, p. 999–1013, August 2014. Citado na página 14.
- MADDEN, S. Database abstractions for managing sensor network data. *Proceedings of the IEEE*, v. 98, p. 1879–1886, 2010. Citado na página 12.
- MILJANOVIC, M. Bayesian networks for imputation in classification problems. "Comparative analysis of Recurrent and Finite Impulse Response Neural Networks in Time Series Prediction", v. 29, n. 3, Feb-Mar 2012. Citado na página 33.
- MYRTVEIT, I.; STENSRUD, E.; OLSSON, U. H. Analyzing data sets with missing data: an empirical evaluation of imputation methods and likelihood-based methods. *IEEE Transactions on Software Engineering*, v. 27, n. 11, p. 999–1013, Nov 2001. Citado na página 13.
- NELSON, D. M. Q. *USO DE REDES NEURAIAS RECORRENTES PARA PREVISÃO DE SÉRIES TEMPORAIS FINANCEIRAS*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais UFMG, Belo Horizonte, Minas Gerais UFMG, 02 2017. Dissertação (mestrado). Citado na página 33.
- PEETERS, B.; ROECK, G. D. One-year monitoring of the z24-bridge: environmental effects versus damage events. *Earthquake Engineering & Structural Dynamics*, v. 30, n. 2, p. 149–171, December 2000. Citado 2 vezes nas páginas 37 e 38.
- PJ, G.-L. et al. Missing data imputation on the 5-year survival prediction of breast cancer patients with unknown discrete values. *Artificial Intelligence in Medicine*, US National Library of Medicine National Institutes of Health, April 2015. Citado na página 12.

- P.R., P. N.; JACKSON, D.; SOMERS, K. How many principal components? stopping rules for determining the number of non-trivial axes revisited. *Computational Statistics and Data Analysis*, n. 49, p. 974–997, 2005. Citado na página 43.
- REYNDERS, E.; HOUBRECHTS, J.; ROECK, G. D. Fully automated (operational) modal analysis. *Mechanical Systems and Signal Processing*, v. 29, p. 228–250, 05 2012. Citado na página 43.
- SAK, H.; SENIOR, A.; BEAUFAYS, F. Long short-term memory recurrent neural network architectures for large scale acoustic modeling. *Journal of Intelligent Information Systems*, 2014. Citado na página 33.
- SANTOS, A. et al. Output-only structural health monitoring based on mean shift clustering for vibration-based damage detection. In: . [S.l.: s.n.], 2016. Citado 2 vezes nas páginas 11 e 12.
- SCHAFER, J. L. Multiple imputation: a primer. *Statistical Methods in Medical Research*, v. 8, n. 1, p. 3–15, 1999. Citado na página 13.
- SCHMITT, P.; MANDEL, J.; GUEDJ, M. A comparison of six methods for missing data imputation. *Journal of Biometrics & Biostatistics*, OMICS International, v. 6, n. 1, 2015. Citado na página 12.
- SOHN, H. Effects of environmental and operational variability on structural health monitoring. *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, The Royal Society, v. 365, n. 1851, p. 539–560, 2007. Citado na página 12.
- SOHN, H. e. a. Data compression: The complete reference. *Secaucus, NJ, USA: Springer-Verlag.*, 2006. Citado na página 19.
- SOVILJ, D. et al. Extreme learning machine for missing data using multiple imputations. *Neurocomput.*, Elsevier Science Publishers B. V., v. 174, n. PA, p. 220–231, jan. 2016. ISSN 0925-2312. Citado na página 12.
- TAN, P.-N.; STEINBACH, M.; KUMAR, V. *Introduction to Data Mining*. Us ed. [S.l.]: Addison Wesley, 2005. Hardcover. ISBN 0321321367. Citado na página 29.
- WENZEL, H. Health monitoring of bridges. *John Wiley & Sons, Ltd.*, n. 185, December 2009. Citado na página 11.
- WERBOS, P. *Beyond regression: New tools for prediction and analysis in the behavioral sciences.* Tese (Ph.D. dissertation, Committee on Appl. Math) — Harvard Univ, Cambridge, MA, Nov, 1974. Citado na página 34.
- WORDEN, K. et al. The fundamental axioms of structural health monitoring. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, v. 463, p. 1639–1664, June 2007. Citado 3 vezes nas páginas 11, 18 e 42.
- WORDEN, K. et al. Structural health monitoring: from structures to systems-of-systems. *IFAC-PapersOnLine*, v. 48, p. 1 – 17, 2015. Citado na página 11.

---

ZAGRAI, A. et al. Piezoelectric wafer active sensor structural health monitoring of space structures. *Journal of Intelligent Material Systems and Structures*, v. 21, n. 9, 2010. Citado na página 17.