



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS FLORIANÓPOLIS
CENTRO TECNÓLOGICO - DEPARTAMENTO DE
ENGENHARIA CIVIL

Pedro Vinícius Gasparotti de Souza

**Aprendizado de máquina não supervisionado para detecção
de danos em pontes rodoviárias**

Florianópolis
2024

Pedro Vinícius Gasparotti de Souza

**Aprendizado de máquina não supervisionado para detecção
de danos em pontes rodoviárias**

Trabalho de Conclusão de Curso de Graduação em Centro Tecnológico - Departamento de Engenharia Civil do Campus Florianópolis da Universidade Federal de Santa Catarina para a obtenção do título de Bacharel em Engenharia Civil.

Orientador: Prof. Tiago Morkis Siqueira, Dr.

Florianópolis

2024

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Souza, Pedro Vinícius Gasparotti de Souza
Aprendizado de máquina não supervisionado para detecção
de danos em pontes rodoviárias / Pedro Vinícius Gasparotti
de Souza Souza ; orientador, Tiago Morkis Siqueira, 2024.
122 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia Civil, Florianópolis, 2024.

Inclui referências.

1. Engenharia Civil. 2. Método dos Elementos Finitos.
3. Inteligência Artificial. 4. Pontes. 5. Monitoramento de
infraestrutura. I. Siqueira, Tiago Morkis. II.
Universidade Federal de Santa Catarina. Graduação em
Engenharia Civil. III. Título.

Pedro Vinícius Gasparotti de Souza

**Aprendizado de máquina não supervisionado para detecção
de danos em pontes rodoviárias**

Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de Bacharel em Engenharia Civil e aprovado em sua forma final pelo Curso de Centro Tecnológico - Departamento de Engenharia Civil.

Florianópolis, 13 de dezembro de 2024.

Prof^a. Dra. Liane Ramos da Silva
Coordenadora do Curso

Banca Examinadora:

Prof. Tiago Morkis Siqueira, Dr.
Orientador
Universidade Federal de Santa Catarina

Prof. Dr. Marcos Souza Lenzi
Avaliador
Universidade Federal de Santa Catarina

Eng. Me. Thiago Moreno Fernandes
Avaliador
Universidade Federal de Santa Catarina

À minha querida Isadora I.

AGRADECIMENTOS

O desenvolvimento tecnológico é um fenômeno que se aproxima do sobrenatural, para os que pensaram além das convicções estabelecidas, o tempo, por diversas vezes, reservou a hostilidade de seus iguais e a descrença em suas descobertas. Surge uma forma universal de comunicar a descoberta de algo novo, manifestada por Aristóteles, Galileu, Jābir ibn Hayyān e incontáveis cientistas que praticaram a teoria alçada em evidências muito antes da formulação do que se conhece hoje por método científico. Agradeço aos cientistas que fundamentaram o meu estudo: Professor Rafael, Professor Tiago, Mestre Thiago, Mestre Gabriel, Vinícius B., Leonardo M. e a todos do CORE que dedicaram seu tempo na pesquisa de tecnologias que vão impactar a forma como se faz engenharia civil. Sou grato a todos da minha família, que sempre incentivaram o estudo, em especial, agradeço aos meus pais, Vanderlei e Sandra, que viabilizaram minha formação acadêmica em Florianópolis, minha irmã Larissa, por todas as vezes que compartilhou sua sabedoria de vida comigo e meu primo Guilherme, que considero como um irmão. Encontrar a Isadora foi a maior felicidade que já vivi, minha inspiração nos momentos mais difíceis e o motivo da minha alegria diária, que tanto me apoiou no desenvolvimento deste e de todos os meus projetos. Minha mais sincera gratidão a todos da turma 18.1, repleta de personalidades incríveis, lar de um time campeão e de amigos que carregarei para a vida. Obrigado Gustavo, Caio, Eduardo, Bernardo, Luisa, Guilherme, Adriel, Lucas, Francisco, Vinícius e Ana que estiveram comigo desde o início da graduação. Do exercício acadêmico aqui disposto, que sirva como ferramenta para o desenvolvimento científico brasileiro, redigido na rica língua portuguesa para indicar as possíveis direções do aprendizado de máquina para a prática da engenharia no nosso país.

RESUMO

Pontes e viadutos são classificados como Obras de Arte da Engenharia devido à natureza de sua concepção: estruturas especiais, cuja finalidade é superar obstáculos naturais e viabilizar a continuidade de uma via modal. Garantir a integridade de estruturas especiais é um desafio no projeto e gerenciamento de infraestrutura, uma vez que a eventual falha dessas componentes talham severos prejuízos econômicos e tragédias humanitárias. Existem duas abordagens predominantes para a aquisição de dados para a avaliação da integridade estrutural: o monitoramento direto, e o monitoramento indireto. No monitoramento indireto é assumida a instalação de sensores no veículo para capturar respostas da interação dinâmica do sistema veículo-estrutura, enquanto na instrumentação do monitoramento direto, os sensores são instalados diretamente na estrutura. O conjunto de dados é obtido a partir de um modelo numérico que simula o comportamento da interação dinâmica do sistema veículo-estrutura. Este trabalho propõe o emprego da inteligência artificial como solução para o monitoramento indireto da saúde estrutural de pontes rodoviárias. As vantagens da abordagem indireta envolvem a capacidade de obter informações espaciais de toda a continuidade da ponte sem a necessidade de interrupção no fluxo do tráfego, bem como a possibilidade do monitoramento de todas as pontes ao longo de uma via rodoviária.

Palavras-chave: Método dos Elementos Finitos. Inteligência Artificial. Pontes. Viadutos. Modelagem Numérica. Monitoramento da Integridade Estrutural.

ABSTRACT

Bridges and overpasses are special structures whose purpose is to overcome natural obstacles and enable the continuity of a transport route. Ensuring the integrity of these structures is a challenge in the design and management of infrastructure, as the eventual failure of these components entails severe economic losses and humanitarian tragedies. Given the impact on the safety of Special Works of Art, there is a need to establish efficient strategies for monitoring structural integrity, with the intention of minimizing interruptions in traffic flow and maximizing the safety of the community dependent on the operation of these systems. There are two predominant approaches to data acquisition for structural integrity assessment: direct monitoring and indirect monitoring. In indirect monitoring, sensors are installed in the vehicle to capture responses from the dynamic interaction of the vehicle-structure system, while in direct monitoring instrumentation, sensors are installed directly on the structure. The advantages of the indirect approach over the direct involve the ability to obtain spatial information from the entire continuity of the bridge without the need for traffic interruption, as well as a significant reduction in the monitoring cost of all bridges and overpasses along a roadway. The data set is generated from a numerical model that simulates the behavior of the dynamic interaction of the vehicle-structure system. Technological development and the refinement of computational capacity have enabled innovative solutions for engineering problems, through artificial neural network algorithms with the potential to adapt and extract information from a given data set. This work proposes the use of artificial intelligence as a solution for the indirect monitoring of the structural health of road bridges and overpasses, and aims to investigate the efficiency and of the use of different autoencoder neural networks architectures for damage identification in highway bridges using indirect monitoring data. Data is generated numerically using a dynamic finite element code developed by the authors. The damage was modeled as stiffness reduction in the finite element closer to the bridge midspan, and the damage identification is evaluated using different damage levels based on the signal reconstruction error.

Keywords: Finite Elements Method. Artificial Intelligence. Bridges. Overpasses. Numerical Modeling. Structural Health Monitoring.

LISTA DE FIGURAS

Figura 1 – Evolução da confiabilidade de estruturas	15
Figura 2 – Ilustração da metodologia indireta proposta	16
Figura 3 – Ilustração do processo de erosão	18
Figura 4 – Experimento de Corbally e Malekjafarian (2022)	23
Figura 5 – Veículo adotado no experimento Corbally e Malekjafarian (2022)	24
Figura 6 – Sensoriamento direto com convolução 2D	25
Figura 7 – Diminuição no número de acidentes em estruturas devido ao avanço tecnológico	28
Figura 8 – Diagrama ilustrado da metodologia	33
Figura 9 – Primeiro algoritmo de aprendizado de máquina atribuído a Samuel (1959)	36
Figura 10 – Big blue derrota Garry Kasparov	37
Figura 11 – Plasticidade cerebral demonstrada em experimentos	38
Figura 12 – Ajuste de regressão linear	40
Figura 13 – Ajuste de regressão linear múltipla	42
Figura 14 – Ajuste de regressão logística com base em duas categorias	45
Figura 15 – Algoritmos de classificação multiclasse	47
Figura 16 – Softmax para classificação de 4 clusters com duas características	49
Figura 17 – Visualização da descida de gradiente	50
Figura 18 – Visualização da descida de gradiente com otimizador adam	53
Figura 19 – Ponto ótimo entre viés e variância Rashidi et al. (2019)	56
Figura 20 – Rede neural de múltiplas camadas (Neural Network, an overview, ScienceDirect 2023)	57

Figura 21 – Unidade de saída, adaptado dos slides de Eric Eaton e Andrew Ng	59
Figura 22 – Adaptado dos slides de Eric Eaton e Andrew Ng	59
Figura 23 – Típica Arquitetura de CNN (Nnalytics Vidhya, 2020)	61
Figura 24 – Procedimento de convolução	62
Figura 25 – Operação de max pooling com filtro (2x2)	63
Figura 26 – Camada totalmente conectada (exemplo para 4 neurônios com ativação ReLU)	64
Figura 27 – Agrupamento k-means	65
Figura 28 – Representação de um autoencoder	66
Figura 29 – Representação do VBI-2D	69
Figura 30 – Representação do sistema dinâmico	73
Figura 31 – Geometria do veículo 2D adotado nas simulações	76
Figura 32 – População de erros de reconstruções de sinais calculados utilizando o MAE CONV2D	84
Figura 33 – Treinamento do autoencoder unidimensional	89
Figura 34 – Treinamento do autoencoder convolucional 1D	90
Figura 35 – Treinamento do autoencoder convolucional 2D	91
Figura 36 – Curvas ROC	94
Figura 37 – Correlação não linear do índice de dano calculado para 10% (DC1) e 20% (DC2) de scour para cenários sem a presença de tráfego	98
Figura 38 – Correlação não linear do índice de dano calculado para 10% e 20% de scour (conv1D DOF 5)	98

LISTA DE TABELAS

Tabela 1 – Tipos de Vistorias Básicas em OAEs	31
Tabela 2 – Tipos de Inspeções Específicas em OAEs	31
Tabela 3 – Tipos de Inspeções	32
Tabela 4 – Frequência das Inspeções	32
Tabela 5 – Estrutura das Camadas de uma Rede Neural	58
Tabela 6 – Parâmetros da Viga	73
Tabela 7 – Faixa de possíveis parâmetros do veículo a cada iteração	75
Tabela 8 – Arquitetura proposta do Autoencoder 1D	79
Tabela 9 – Arquitetura proposta do Autoencoder Conv1D	80
Tabela 10 – Arquitetura proposta do Autoencoder Conv2D	87
Tabela 11 – Flutuação do modelo CONV1D do índice de dano (DOF 6 - eixo traseiro)	89
Tabela 12 – Flutuação do modelo CONV2D do índice de dano (DOF 6 - eixo traseiro)	90
Tabela 13 – Flutuação do modelo CONV1D do índice de dano (DOF 5 - truque traseiro do eixo frontal)	91
Tabela 14 – Flutuação do modelo CONV2D do índice de dano (DOF 5 - truque traseiro do eixo frontal)	92
Tabela 15 – Flutuação CONV2D no cálculo do índice de dano (DOF 1 - cabine)	92
Tabela 16 – Flutuação CONV1D no cálculo do índice de dano (DOF 1 - cabine)	92
Tabela 17 – Resumo dos resultados de classificação com k-means	93

SUMÁRIO

1	INTRODUÇÃO	14
1.1	MOTIVAÇÃO	17
1.2	OBJETIVOS	19
2	REVISÃO BIBLIOGRÁFICA	21
2.1	TRABALHOS RELACIONADOS	21
2.2	MONITORAMENTO DA INTEGRIDADE ESTRUTURAL	27
2.3	METODOLOGIA INDIRETA DE INSPEÇÃO	32
2.4	APRENDIZADO DE MÁQUINA	36
2.5	APRENDIZADO SUPERVISIONADO	39
2.5.1	Problemas de Regressão	39
2.5.2	Problemas de classificação	42
2.6	DESCIDA DE GRADIENTE	50
2.6.1	Overfitting	52
2.7	REDES NEURAIS	57
2.7.1	Propagação para frente (forward propagation)	58
2.7.2	Retropropagação (backpropagation)	59
2.8	REDES NEURAIS CONVOLUCIONAIS	60
2.8.1	Arquitetura da Rede	61
2.9	APRENDIZADO NÃO SUPERVISIONADO	63
2.9.1	Autoencoders para detecção de Danos	65
3	COLETA DE DADOS	68
3.1	INTERAÇÃO VEÍCULO-ESTRUTURA	68
3.1.1	Fundamentos da Modelagem	68
3.2	VBI-2D	72
3.2.1	Descrição das iterações do algoritmo para geração da base de dados	74
3.2.2	Modelagem da erosão na base das fundações	75

4	METODOLOGIA PARA O EMPREGO DO APREN-	
	DIZADO NÃO SUPERVISIONADO	78
4.1	DETECÇÃO DE ANOMALIAS	82
4.2	CÁLCULO DO INDICADOR DE DANO	85
5	APRESENTAÇÃO DOS RESULTADOS	88
5.1	RESULTADOS DOS ÍNDICES DE DANO	88
5.1.1	Classificação não supervisionada com K-Means .	90
5.1.2	Curvas ROC	92
6	CONCLUSÕES E PROPOSTAS PARA TRABA-	
	LHOS FUTUROS	95
6.1	DISCUSSÃO DOS RESULTADOS	95
6.2	CONCLUSÕES	96
6.3	RECOMENDAÇÕES PARA TRABALHOS FUTUROS	97
	Bibliografia	100

1 INTRODUÇÃO

Pontes e viadutos são classificados como Obras de Arte da Engenharia (OAEs) devido à natureza de sua concepção: estruturas especiais, cuja finalidade é superar obstáculos naturais e viabilizar a continuidade de uma via modal, conforme estabelecido pela Associação Brasileira de Normas Técnicas (ABNT) (NBR, 2023).

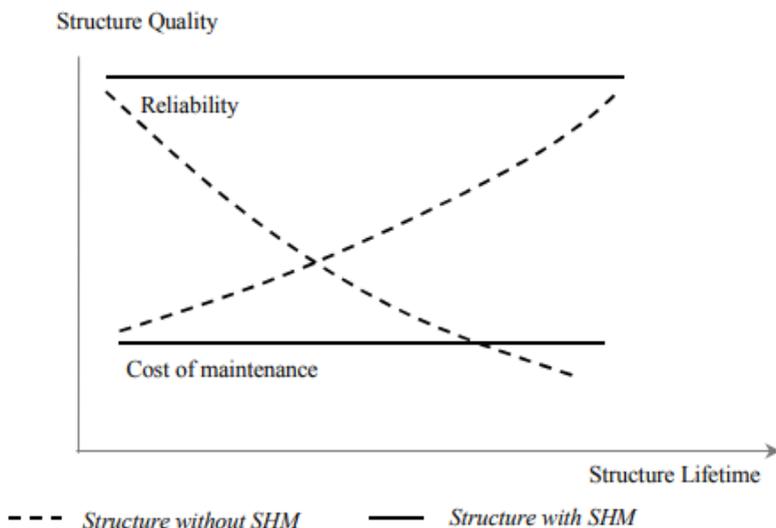
Garantir a integridade de estruturas especiais é um desafio no projeto e gerenciamento de infraestrutura, uma vez que a eventual falha dessas componentes talham severos prejuízos econômicos e tragédias humanitárias. Essas estruturas sofrem processos de deterioração devido à exposição a agentes agressivos ambientais e solicitações estruturais diversas, comprometendo sua segurança, funcionalidade, resistência, estabilidade e durabilidade ao longo do tempo. Para manter a integridade das OAEs, inspeções periódicas são necessárias para identificar, prevenir e corrigir processos de deterioração.

Desde as primeiras pontes que se tem registro na Babilônia por volta de 2000 a.C., conforme levantado por Rich (1875), até as estruturas romanas em pedra e madeira, os materiais evoluíram significativamente, e com o surgimento do concreto de cimento Portland no final do século XIX, foram criadas as primeiras patentes de sistemas construtivos em concreto armado, proporcionando obras mais econômicas e variadas, conforme discutido por (Béton, 2000).

O emprego de modelos modernos de previsão de vida útil reduz exageros antieconômicos e minimiza equívocos decorrentes de análises simplificadas ou falta de qualificação profissional, e o terceiro nível de projeto de durabilidade permite alcançar a vida útil desejada com maior precisão e economia. A Teoria da Confiabilidade, que introduz conceitos estatísticos e índices de segurança para uma determinada vida útil, representa o estágio mais avançado atualmente empregado,

de acordo com (Mitre, 2005), embora ainda em desenvolvimento e pouco difundido.

Figura 1 – Evolução da confiabilidade de estruturas



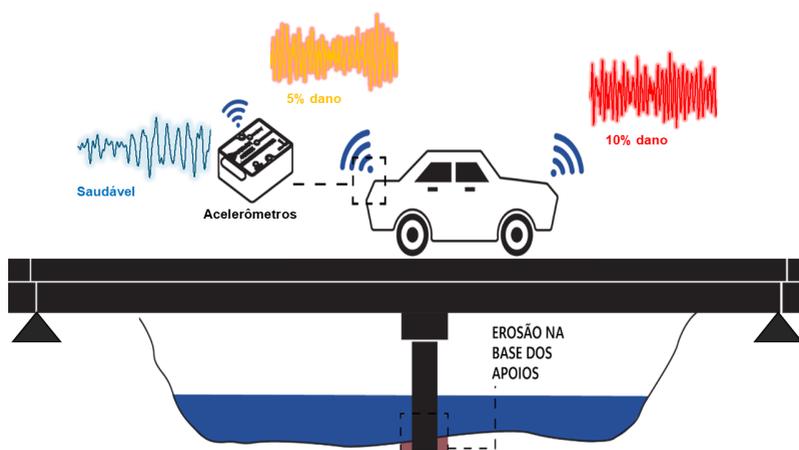
Fonte: Adaptado do livro de Balageas et al. (2006)

Determinado o impacto acometido à segurança das OAEs, surge a necessidade de estabelecer estratégias eficientes de monitoramento da integridade estrutural, com a intenção de minimizar as interrupções no fluxo do tráfego, e maximizar a segurança da comunidade dependente da operação destes sistemas. Existem duas abordagens predominantes para aferir a integridade estrutural de determinada infraestrutura: o monitoramento direto e o monitoramento indireto.

No monitoramento indireto é presumida a instalação de sensores no veículo para capturar respostas da interação dinâmica do sistema veículo-estrutura, enquanto na instrumentação do monitora-

mento direto, os sensores são instalados diretamente na estrutura. A abordagem indireta possui a capacidade de obter informações espaciais de toda a continuidade da ponte sem a necessidade da interrupção da circulação de veículos, bem como a possibilidade de um monitoramento de todas as pontes e viadutos ao longo da extensão da via com o mesmo sistema de aquisição de dados.

Figura 2 – Ilustração da metodologia indireta proposta



Este trabalho propõe o emprego da aprendizagem de máquina como solução para o monitoramento indireto da saúde estrutural de pontes e viadutos rodoviários. Para avaliar a metodologia, é coletada uma base de dados obtidos de uma simulação computacional entre um veículo e uma ponte de concreto, com a finalidade de inferir a presença e a intensidade de um dano induzido pela perda de rigidez no apoio central da ponte.

1.1 MOTIVAÇÃO

A preocupação com a durabilidade das estruturas de concreto é um tópico relativamente recente na indústria da construção civil, e substituiu a superada crença de que tais obras, como pontes, seriam eternas, conforme elencado por Mitre (2005).

Ações ambientais e de utilização, associadas a fatores inerentes ao projeto da estrutura iniciam processos de envelhecimento, dano ou obsolescência que reduzem a capacidade das obras-de-arte especiais (OAEs) de atender aos requisitos de funcionalidade, segurança estrutural e durabilidade. Inúmeros incidentes ilustram que a perda gradual ou abrupta da capacidade resistente ou funcional pode comprometer o serviço ou até provocar a ruína da estrutura, tópico abordado por autores como Farrar e Worden (2012) e Balageas et al. (2006) a respeito do monitoramento da saúde estrutural (Structural Health Monitoring).

Processos de deterioração, em sua maioria, desenvolvem-se gradualmente, com manifestações visíveis ou detectáveis por ensaios específicos, por conseguinte, é possível identificar, diagnosticar e solucionar problemas antes de proporções graves serem atingidas, acarretando elevados custos financeiros e sociais.

Acompanhar periodicamente as OAEs, por meio de vistorias e inspeções detalhadas, executadas conforme procedimentos padronizados e tecnicamente adequados, é o meio mais eficaz para subsidiar políticas de manutenção corretiva e preventiva, garantindo economia, segurança e alocação racional dos recursos conforme a urgência de intervenção de cada obra.

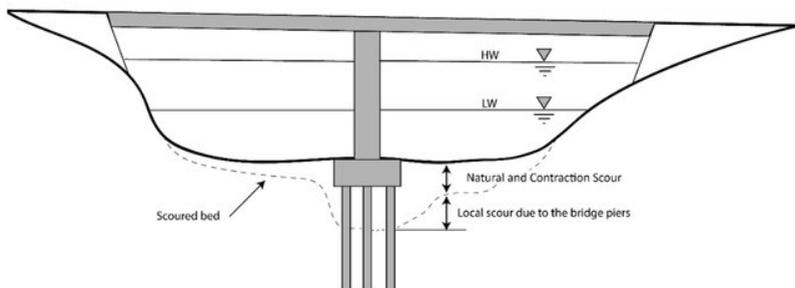
Mitre (2005), em seu trabalho, disserta sobre a falta de um conhecimento profundo do estado geral das OAEs brasileiras. Conforme elencado por Helene (1993), estima-se um patrimônio nacional, que

na época, seria de 30 a 50 mil pontes, algumas estimativas recentes de entidades independentes, como o Ibracon (2019), apontam um patrimônio de 137 mil pontes, avaliadas em R\$ 260 bilhões. Landman (2001) sintetizou a vistoria de 742 OAEs de rodovias federais, mostrando que 34% apresentavam problemas de durabilidade e até 67% tinham problemas funcionais - a maioria dos problemas estruturais originava-se de questões de durabilidade que afetavam a segurança estrutural.

A erosão de fundações é um problema crítico que pode levar ao colapso de pontes, problema amplamente discutido na literatura, e detalhado no estudo de T. Fernandes et al. (2024).

No ímpeto do gerenciamento desse risco, diversas metodologias são utilizadas para inferir a integridade estrutural de pontes, indo além das inspeções visuais rotineiras, posto que estas não prevêm o acesso a componentes da infraestrutura que ficam submersos, ficando estes procedimentos reservados apenas para inspeções detalhadas, conforme a instrução da norma NBR 9452 (NBR, 2023) vigente.

Figura 3 – Ilustração do processo de erosão



Fonte: Por Pizarro et al. (2020)

Entre essas metodologias, o monitoramento assistido por veículos se destaca como uma alternativa promissora devido à sua escalabi-

lidade, e da facilidade de instalação de sensores em comparação com a instrumentação direta das pontes, um dos motivos, além do alto custo de instalação do sensoramento direto e a exposição do sistema de aquisição aos intemperismos ambientais, é a curta vida útil do equipamento quando comparada à vida útil da ponte a ser monitorada, segundo Cong Ye e Middleton (2022).

Os métodos *drive-by* representam uma abordagem que dispensa a necessidade da instrumentação individualizada de cada ponte, monitorando-as através da análise das respostas dinâmicas da interação veículo-estrutura. No entanto, a implementação prática desses métodos enfrenta desafios significativos.

De acordo com Fitzgerald et al., 2019, tais obstáculos incluem a dependência de veículos específicos e a variabilidade das condições operacionais e ambientais, que podem obscurecer os dados coletados com ruídos e variações indesejadas.

Ao incorporar variabilidades nos métodos numéricos, é possível aproximar as condições de simulação às condições reais do fenômeno objeto de estudo, permitindo uma avaliação menos enviesada da eficiência da metodologia proposta.

Quanto aos veículos, podem ser utilizados modelos com distintas propriedades físicas, como massa, rigidez da suspensão, amortecimentos e diferentes velocidades aleatórias geradas a cada passagem e a rugosidade da superfície pode a partir da função de densidade espectral de potência (PSD) definidas pela norma ISO 6082016 (ISO, 2016), com amplitudes geradas aleatoriamente dentro da classe A.

1.2 OBJETIVOS

O objetivo deste trabalho é avaliar a eficácia de um conjunto de modelos de aprendizado não supervisionado na detecção de diferentes

graus de erosão na base dos apoios em pontes rodoviárias de concreto, e o uso destas ferramentas como atributo para a tomada de decisão com base em dados no contexto do monitoramento da integridade estrutural (SHM - Structural Health Monitoring).

Para a coleta de dados, foi utilizado o modelo numérico VBI-2D fundamentado no método dos elementos finitos, e desenvolvido por Cantero (2024), este procedimento é detalhado no capítulo 4.

A metodologia proposta visa a identificação precoce de anomalias, mesmo em estágios iniciais e baixos níveis de dano, viabilizando cenários de manutenção preventiva, aumentando a segurança de ativos críticos de infraestrutura viária.

Os objetivos secundários são a análise da progressão do índice de dano calculado a partir da divergência de informação entre distribuições de erros de reconstrução de sinais bem como avaliar o estado da arte da prática do monitoramento e inspeção de OAEs.

São avaliados diferentes modelos de aprendizado não supervisionado, treinados na tarefa de reconstruir dados de aceleração da interação entre veículos e pontes em estado saudável. Baseando-se nos erros de reconstrução do modelo, são identificados os desvios que denotam o grau e a presença de anomalias na estruturad

Os dados são gerados considerando diversas passagens de um cenário em que apenas um veículo interage com a estrutura. A cada passagem, é gerado um veículo com diferentes propriedades mecânicas de massa, elasticidade e amortecimento, além de irregularidades viárias e ruídos de medição, aproximando a simulação computacional da manifestação real do fenômeno físico objeto de estudo.

2 REVISÃO BIBLIOGRÁFICA

2.1 TRABALHOS RELACIONADOS

O aumento da eficiência computacional escalou a aplicação de técnicas de aprendizado de máquina a resolução de problemas de engenharia. Novos estudos buscam métodos eficientes para detectar problemas estruturais utilizando uma abordagem data-driven. Malekjafarian et al. (2015) foram pioneiros ao utilizar redes neurais artificiais (RNA) para detectar danos em pontes a partir de medições de aceleração em veículos que as atravessam.

Eles treinaram uma RNA usando dados de aceleração e velocidade de veículos sobre uma ponte em condições intactas. Posteriormente, aplicaram um processo Gaussiano aos erros de predição da rede para identificar aumentos causados por danos estruturais.

Embora o método tenha se mostrado eficaz na detecção de danos, não considerou efeitos ambientais, como variações de temperatura, que podem influenciar significativamente o comportamento da ponte.

No ano seguinte, Locke et al. (2020) avançaram nessa linha de pesquisa ao empregar redes neurais convolucionais (CNN) para a detecção de danos em pontes rodoviárias. No estudo de Locke et al. (2020), foram consideradas variáveis como temperatura, velocidade do veículo, tráfego e irregularidades do pavimento em seu modelo.

Apesar de a CNN ter demonstrado capacidade de detecção em condições mais próximas da realidade, o método enfrentou dificuldades em distinguir a progressão dos danos. Isso exigiu um novo treinamento da rede após a ocorrência de danos, o que limita sua aplicação prática, já que danos podem ocorrer de forma súbita.

Sarwar e Cantero (2021) propuseram uma metodologia baseada em um autocodificador profundo (DAE) treinado com respostas de

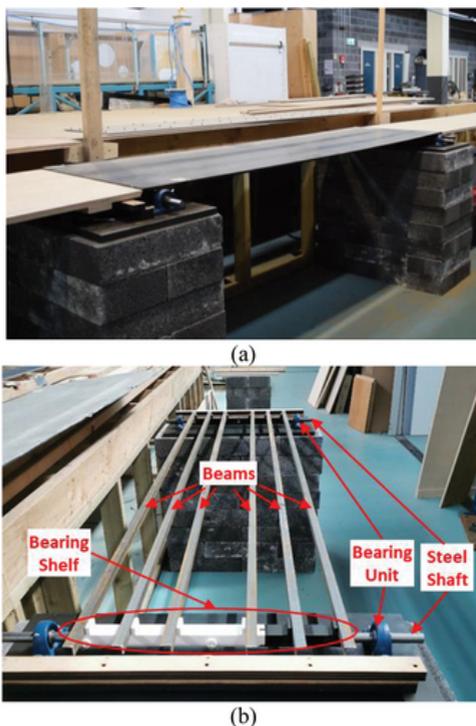
aceleração vertical de veículos cruzando uma ponte intacta. O DAE, que utiliza camadas convolucionais e redes de memória de curto e longo prazo (LSTM), extrai atributos sensíveis aos danos, permitindo sua detecção. O método mostrou eficácia sob diversas condições operacionais, mas ainda precisa ser testado considerando efeitos ambientais como variações de temperatura e vento, que podem afetar os resultados.

Corbally e Malekjafarian (2022) contribuíram ao utilizar redes neurais artificiais para avaliar as respostas da ponte a partir de medições de aceleração em veículos em movimento. A inovação deles foi inferir a resposta no ponto de contato entre o pneu e o pavimento, propondo um novo indicador de dano que permite visualizar a progressão ao longo do tempo. Esse método mostrou-se eficiente na detecção de trincas, mesmo considerando irregularidades no pavimento e ruídos nas medições, além de minimizar influências externas como a temperatura ambiente.

Ainda em 2022, Mokalled et al. (2022) desenvolveram uma abordagem probabilística baseada em estimação Bayesiana para identificar danos sem a necessidade de dados previamente rotulados. Utilizando dados brutos de aceleração dos veículos, o método conseguiu detectar a presença, localização e severidade dos danos, no entanto, mostrou-se sensível ao nível de ruído e à velocidade do veículo, e não foram consideradas irregularidades do pavimento ou fatores ambientais, o que pode limitar sua aplicabilidade em situações reais.

Em 2023, Li et al. (2023a) propuseram uma metodologia baseada em autocodificador profundo para a detecção automática de danos em tempo real, utilizando sinais de curto prazo coletados de veículos durante a passagem pela ponte. A abordagem demonstrou eficiência e alta precisão em diferentes cenários de dano. Contudo, não abordou efeitos externos, como irregularidades do pavimento que

Figura 4 – Experimento de Corbally e Malekjafarian (2022)



Fonte: Fonte: Corbally e Malekjafarian (2022)

podem afetar severamente a acurácia da detecção.

Também em 2023, Sarwar e Cantero (2023) apresentaram uma metodologia que combina monitoramento direto e indireto, empregando redes neurais profundas probabilísticas com aproximação Bayesiana. Essa técnica permite quantificar as incertezas na identificação de danos e mostrou capacidade de detectar, localizar e quantificar danos sob diversas variabilidades operacionais e ambientais. No entanto, a necessidade de dados rotulados para o treinamento e a exigência de

Figura 5 – Veículo adotado no experimento Corbally e Malekjafarian (2022)



Fonte: Corbally e Malekjafarian (2022)

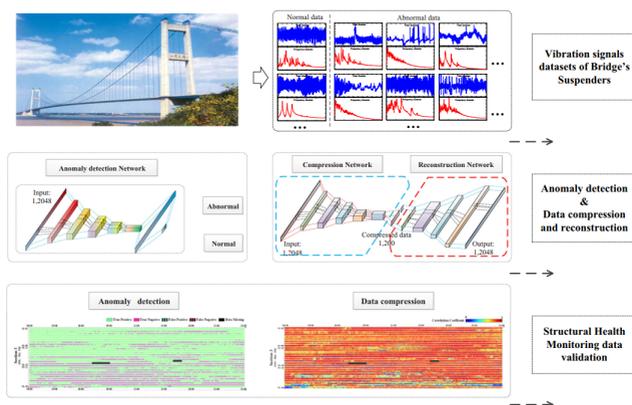
sinais sincronizados de múltiplos sensores, inclusive na ponte, podem tornar sua aplicação prática mais onerosa e complexa.

No campo da detecção de anomalias em pontes rodoviárias, diversos pesquisadores têm explorado técnicas avançadas de aprendizado de máquina e processamento de dados para aprimorar o monitoramento estrutural. Fallahian et al. (2018) propuseram uma abordagem que combina algoritmos de codificação esparsa com redes neurais convolucionais (CNN) para avaliar danos estruturais sob variações de temperatura. Eles extraíram atributos da Função de Resposta em Frequência (FRF) dos dados medidos e os inseriram tanto na CNN quanto no algoritmo de codificação esparsa para desenvolver um classificador eficiente.

No trabalho de Ni et al. (2020) foi proposta uma nova metodologia para compressão e reconstrução de dados de aceleração utilizando técnicas de aprendizado profundo. A metodologia se divide em duas fases: primeiro, uma rede neural convolucional unidimensional (CNN) é projetada para extrair atributos diretamente dos sinais de entrada, vi-

sando detectar anomalias com alta precisão; segundo, um novo método de compressão e reconstrução de dados de monitoramento estrutural (SHM) é desenvolvido com base na estrutura de um autocodificador, permitindo recuperar os dados com alta fidelidade mesmo com baixa taxa de compressão.

Figura 6 – Sensoriamento direto com convolução 2D



Fonte: \textcite {Ni2020}

Para validar a abordagem, utilizaram dados de aceleração de uma ponte suspensa de grande vão localizada na China. A metodologia alcançou uma acurácia de 97,53% com uma taxa de compressão de 10%, demonstrando eficiência na detecção de anomalias e na economia de armazenamento de dados. Sarmadi e Karamodin (2020) propuseram uma abordagem não supervisionada para detecção de anomalias, baseada na distância quadrática adaptativa de Mahalanobis (AMSD) e na técnica dos k-vizinhos mais próximos (k-NN), aplicada ao monitoramento estrutural sob variabilidade de condições ambientais.

No estudo conduzido por Mao et al. (2021), os pesquisadores combinaram duas redes neurais profundas, as Redes Adversárias Ge-

nerativas (GANs) e os Autocodificadores (AEs), com o objetivo de eliminar anomalias em dados provenientes de sistemas de sensores defeituosos. Os conjuntos de dados temporais coletados do sistema de monitoramento estrutural foram transformados em imagens utilizando o método Gramian Angular Field (GAF). Essas imagens serviram para treinar os algoritmos GANs e AEs. Dados de aceleração medidos em uma ponte real de grande vão, incluindo informações anômalas causadas por falhas nos sensores, foram empregados para validar a metodologia.

Embora o aprendizado não supervisionado tenha alcançado alta acurácia na detecção de anomalias, o modelo classificou os dados apenas em duas categorias—anômalos e normais—sem especificar os tipos específicos de anomalias presentes. ZHANG et al. (2022) apresentaram uma técnica de detecção de anomalias em dados de aceleração que combina redes neurais convolucionais (CNN) com atributos estatísticos tradicionais, como curtose e valor quadrático médio (RMS). Segundo os autores, essa combinação permite uma detecção de anomalias mais rápida e precisa do que o uso exclusivo de CNNs.

A metodologia foi validada com dados de aceleração de uma ponte, e os resultados indicaram uma eficácia de 94,26% na identificação de dados anômalos.

Lei et al. (2023) introduziram um algoritmo denominado Rede de Atenção Residual (RAN) para a detecção de anomalias em dados de aceleração de pontes rodoviárias. O algoritmo combina mecanismos de atenção com aprendizado residual profundo, visando aumentar a eficiência e a precisão da detecção. Os autores propuseram um procedimento de pré-processamento de dados baseado em transformação mútua de informações para identificar os atributos característicos de cada tipo de dado anômalo.

Para validar a metodologia e testar a capacidade de generali-

zação do algoritmo, foram estudados dois tipos de pontes reais: uma ponte em arco, localizada na China, e uma ponte estaiada. Os resultados mostraram que a metodologia foi eficaz em identificar a maioria dos tipos de anomalias nos dados, apresentando excelente desempenho de classificação. Além disso, o algoritmo RAN superou o desempenho da Rede Residual (ResNet), outra técnica de aprendizado profundo amplamente utilizada, destacando-se como uma abordagem promissora no contexto do monitoramento estrutural.

2.2 MONITORAMENTO DA INTEGRIDADE ESTRUTURAL

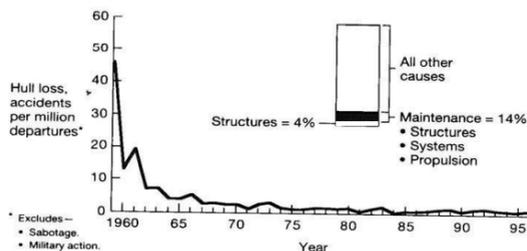
A prática do monitoramento da saúde estrutural (SHM, de Structural Health Monitoring) é uma manifestação natural da busca por métodos capazes de compreender e preservar a integridade de sistemas complexos e relevantes.

A definição de monitoramento da saúde estrutural proposta por Farrar e Worden (2012) se refere ao processo de implementação de uma estratégia de detecção de danos para infraestrutura aeroespacial, civil ou mecânica através da observação de medições de respostas dinâmicas espaçadas periodicamente. Das medições são extraídas características sensíveis a comportamentos estruturais anômalos, detectados através de técnicas estatísticas de inferência.

O objetivo do monitoramento da saúde estrutural é a informação periodicamente atualizada sobre a capacidade da estrutura de continuar a desempenhar sua função pretendida, à luz do envelhecimento e degradação inevitáveis resultantes dos ambientes operacionais. Uma analogia instrutiva, proposta por Mitre (2005), é estabelecida entre o processo de inspeção de estruturas e a prática médica.

O trabalho de inspecionar, diagnosticar, avaliar e propor intervenções em uma estrutura aproxima-se do exercício médico. Os

Figura 7 – Diminuição no número de acidentes em estruturas devido ao avanço tecnológico



Fonte: Balageas et al. (2006)

sintomas representam as manifestações patológicas que podem ser analisadas através de observações visuais, ensaios realizados "in loco" ou com amostras em laboratório. Reunidas as informações, o profissional busca interpretar as observações por meio dos resultados e indícios complementares para estabelecer um diagnóstico, sujeito à precisão, profundidade e abrangência das informações disponíveis.

São disciplinas afins ao SHM o Monitoramento de Condição (CM), voltado a máquinas rotativas; a Avaliação Não Destrutiva (NDE), empregada em inspeções específicas; os Sistemas de Monitoramento de Saúde e Uso (HUMS), aplicados a trens de acionamento; e o Controle Estatístico de Processo (SPC), com foco específico em processos. CM, NDE e SPC são as disciplinas de detecção de danos mais maduras, pois fizeram a transição de um tópico de pesquisa para a prática de engenharia real para uma ampla variedade de aplicações.

SHULL (2001) denota já em 2001 que a capacidade de monitorar estrutura e detectar danos em estágios iniciais é de interesse generalizado nas comunidades de engenharia civil, mecânica e aeroespacial, porém, a maioria dos métodos atuais de detecção de danos é baseada em NDE, com o exercício de métodos visuais ou experimen-

tais localizados, como ensaios acústicos, radiografia, corrente parasita e ou campo térmico, apontados por KAISER e KARBHARI (2004).

Essas técnicas experimentais elencadas demandam um conhecimento prévio acerca da vizinhança do dano, e também algum acesso à região de interesse, destarte, a investigação para aferir o estado de conservação de uma obra especial de infraestrutura exige uma definição preliminar de objetivos antes da confirmação operacional de uma série de premissas, tornando o processo intrinsecamente enviesado desde a concepção.

Inicialmente, são estabelecidos os resultados esperados, as limitações existentes já conhecidas, os recursos e o tempo disponível, para então planejar as atividades, a demanda de recursos e estabelecer um cronograma. Porém, apenas após a primeira inspeção e a coleta de dados, é possível ser feito qualquer diagnóstico para confirmar as premissas pré-estabelecidas. Prescritos os dados, é elaborado o prognóstico da evolução futura dos problemas para cenários onde não se estabelece a necessidade de intervenção, ou, quando requerido, do protocolo de intervenções, sejam essas preventivas ou corretivas (BÉTON, 1989).

Métodos diretos de inspeção

Diferentes tipos de inspeção diretas in loco podem ser aplicados, cuja distinção principal é feita por:

- Quantidade e nível de detalhamento dos dados a serem coletados;
- Demanda de recursos e equipamentos para acesso e ensaio da estrutura;
- Prazo de execução dos serviços de campo e escritório;
- Qualificação da equipe de inspeção.

A NBR 9452 (NBR, 2023) delimita três categorias de inspeção que constituem o arcabouço do diagnóstico e da gestão das condições de pontes, viadutos e passarelas de concreto.

A **inspeção cadastral**, em sua essência, representa o ponto inaugural do registro sistemático, cujo objetivo é reunir informações básicas para fins de cadastro e gerenciamento. Já a **inspeção rotineira**, realizada em intervalos regulares, é o que mais se aproxima de uma ação preventiva, examinando o estado geral da estrutura e identificando eventuais sinais de deterioração, como fissuras, danos na armadura, falhas no concreto, problemas nos apoios, juntas e encontros.

A **inspeção especial** é realizada quando há suspeita de algum problema específico na ponte, como danos estruturais ou deterioração. Ela pode ser necessária após eventos imprevisíveis ou se uma inspeção rotineira identificar problemas que exigem investigação mais aprofundada, e pode incluir análises estruturais, provas de carga, ensaios tecnológicos e até inspeção subaquática.

É recomendada uma periodicidade de cinco anos pela NBR 9452 para esta modalidade de inspeção, podendo ser postergada até 8 anos quando a classificação obtida nas inspeções rotineiras é de intervenção de longo prazo, ou obras com total acesso a seus elementos constituintes na inspeção rotineira.

O sistema de notas proposto pela norma varia de 1 a 5, onde 1 representa a situação mais crítica, e 5 a condição ideal. Este mesmo sistema de pontuação orienta a priorização das intervenções.

Inspeções de pontes frequentemente se restringem às duas etapas iniciais, vistoria do local, e análise de dados históricos, e inspeções mais detalhadas são menos comuns, devido a sua onerosidade em termos de custo e tempo. As pesquisas são raras, ocorrendo apenas quando a experiência prática ou o conhecimento teórico dos técni-

Tipo de Vistoria	Descrição
Vistoria de conhecimento	Estudos iniciais expeditos para identificação dos principais problemas e estimativas de custos futuros.
Vistoria cadastral	Levantamento de dados geométricos e condições gerais da OAE, com abordagem visual e expedita.
Vistoria rotineira	Observação visual periódica para verificar alterações e atualizar banco de dados do SGO.

Tabela 1 – Tipos de Vistorias Básicas em OAEs

Tipo de Inspeção	Descrição
Inspeção CVC	Avaliação antes e depois da passagem de cargas especiais, incluindo definição de condições de travessia.
Inspeção de capacidade	Realização de ensaios e provas de carga para verificação estrutural em OAEs obsoletas ou danificadas.
Inspeção especial	Estudos detalhados com ensaios e medições para avaliação de danos e anomalias existentes.

Tabela 2 – Tipos de Inspeções Específicas em OAEs

cos não permite definir um diagnóstico provável a partir dos dados levantados.

Etapas do processo de inspeção

A etapa inicial é a identificação da necessidade de uma inspeção, sendo essa uma atribuição do órgão gestor responsável pela integridade da infraestrutura (a concessionária, no caso de uma malha sob concessão, ou o a entidade governamental no caso de uma via pública).

Diversos fatores podem motivar essa decisão, inclusive chamados da população recebidos em ouvidorias públicas. Na ausência de um motivo específico, realiza-se periodicamente uma inspeção rotineira para atualização do banco de dados do SGO. Quando a necessidade de inspeção é definida, o contratante deve especificar as informações requeridas e os prazos de execução estabelecidos pelo Departamento Nacional de Infraestrutura de Transportes (DNIT, 2004).

Tipo de Inspeção	Finalidade
Levantamento de Informações	Coleta de projetos e dados históricos
Inspeção Preliminar	Planejamento e identificação inicial
Inspeção Detalhada	Análise completa e documentação

Tabela 3 – Tipos de Inspeções

Tipo	Frequência
Cadastral	Após conclusão/alterações
Rotineira	2 anos máximo
Especial	5 anos máximo
Extraordinária	Após acidentes graves

Tabela 4 – Frequência das Inspeções

2.3 METODOLOGIA INDIRETA DE INSPEÇÃO

O monitoramento indireto, em contraste ao monitoramento direto, envolve a observação de parâmetros que não estão diretamente relacionados à integridade física da estrutura, mas que podem fornecer informações sobre a presença e a extensão de danos.

Farrar e Worden (2012) propõe que a observação contínua na mudança de características indiretas, como a vibração de outros corpos

extensos interagindo com a estrutura, servem como atributo a ser utilizado no prognóstico de danos.

Fernandes e Lopez (2023) propõe uma metodologia de monitoramento indireto "drive-by" contínuo para pontes ferroviárias, utilizando um modelo de autoencoder profundo e um indicador de danos.

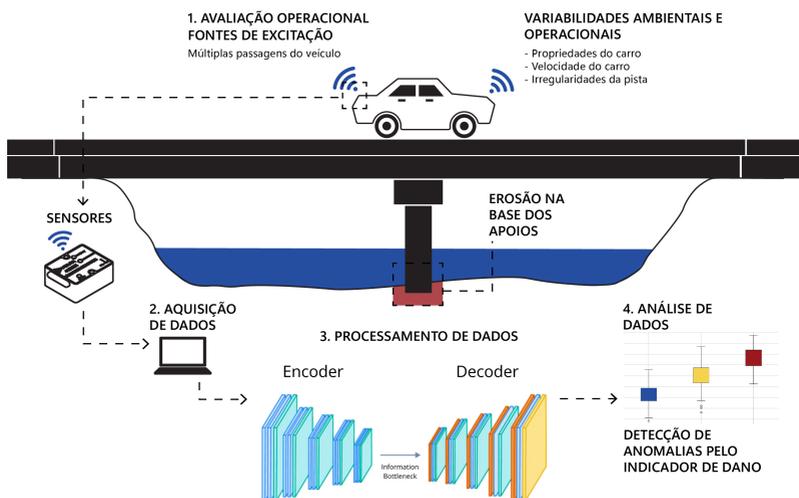


Figura 8 – Diagrama ilustrado da metodologia

Avaliação operacional

Nesta fase inicial, o foco é a coleta de informações relevantes sobre o sistema a ser monitorado. Isso inclui:

- **Fontes de Excitação:** Identificar as principais fontes de vibração que atuam sobre a ponte, como a passagem de trens, ventos fortes ou atividades sísmicas.

- **Variáveis Operacionais e Ambientais (EOVs):** Compreender as variáveis que podem influenciar o comportamento da estrutura, como velocidade do trem, irregularidades nos trilhos, temperatura ambiente e umidade.
- **Limitantes na Aquisição de Dados:** Analisar as restrições e desafios na coleta de dados no ambiente operacional, como acessibilidade, custos e segurança.

Aquisição de dados

A segunda etapa envolve a coleta de dados por meio de sensores instalados nos veículos que trafegam sobre a ponte.

- **Sensores:** Acelerômetros piezoelétricos são preferencialmente utilizados devido à sua alta precisão, custo-benefício e capacidade de operar em altas temperaturas.
- **Posicionamento dos Sensores:** Os sensores são posicionados em diferentes locais do veículo: na cabine, eixos das rodas, para capturar as respostas vibracionais da estrutura sob diferentes perspectivas.
- **Sincronização e Limitações:** A aquisição de dados é sincronizada com o sistema de posicionamento global (GPS) para garantir a precisão na captura dos sinais.
- **Ruído de Medição:** Para simulações numéricas, é considerado um ruído inerente aos sensores, induzido de forma aleatória para se aproximar das condições reais de operação.

Processamento e análise de dados

Os dados brutos de aceleração coletados são processados por um modelo de autoencoder profundo para extrair características relevantes e detectar anomalias indicativas de danos, e a última etapa consiste na análise dos resultados do processamento de dados para identificar a presença e a intensidade dos danos na ponte.

Primeiramente, são gerados dados numéricos de aceleração de um veículo atravessando uma ponte, considerado variabilidades operacionais de velocidade do veículo e irregularidade do asfalto. Por fim, são processados os dados por meio do treinamento não supervisionado dos algoritmos para a detecção de anomalias.

O treinamento é realizado apenas com os dados de aceleração da estrutura da ponte sem dano. Após a extração de atributos, o modelo treinado é utilizado para computar o erro de reconstrução dos dados de teste, que envolvem respostas de estruturas com dano induzido.

No intuito de comparar a adequação de diferentes abordagens, este trabalho aplicou, na mesma base de dados, uma arquitetura unidimensional sem camadas convolucionais, uma arquitetura de uma dimensão com camadas de convolução e uma arquitetura 2D com camadas convolucionais, todas com um canal de entrada contendo as respostas de aceleração coletadas da simulação numérica.

Dessa forma, é possível avaliar se as convoluções 2D podem influenciar na convergência e na qualidade da reconstrução. A arquitetura do modelo unidimensional, composta por camadas densas, foi incorporada como um modelo de referência a ser superado, dado que é um modelo mais simples e generalista do que arquiteturas munidas de camadas convolucionais, mais dimensões e mais canais.

2.4 APRENDIZADO DE MÁQUINA

Machine Learning é o campo de estudo que dá aos computadores a habilidade de aprender sem ser explicitamente programado. Essa é a definição atribuída a Samuel (1959) que programou um computador para aprender a jogar damas a partir de um conjunto de dados de partidas completas e da informação acerca de quais foram as jogadas que resultaram em uma vitória.

Contudo, apenas após lograr grandes sucessos no final da década de 90, a inteligência artificial atraiu a atenção da comunidade científica global.

Figura 9 – Primeiro algoritmo de aprendizado de máquina atribuído a Samuel (1959)



Fonte: The games that helped AI evolve (IBM)

Sistemas como o R1, descrito em McCorduck (2004), e o Deep Blue, discutido em M. Campbell et al. (2002), demonstraram o potencial do aprendizado de máquina quando aplicado a problemas concretos, substituindo a busca pela reprodução do pensamento humano de forma artificial, conforme realçado por Russell e Norvig (2010).

Em 1982, o R1 tornou-se o primeiro sistema especialista comercialmente bem-sucedido, operando na Digital Equipment Corporation,

revolucionando o processo de configuração de pedidos para novos sistemas computacionais, proporcionando uma eficiência relevante, ao ser capaz de entregar uma economia 40 milhões de dólares anuais, em apenas quatro anos. Até 1988, seu impacto catalisou a implantação de 40 sistemas especialistas adicionais.

Paralelamente, a vitória do Deep Blue sobre o campeão mundial de xadrez Garry Kasparov, após uma polêmica sequência de jogos em 1996, alcançou a grande mídia, demonstrando o potencial da aprendizagem de máquina em tarefas de alto desempenho cognitivo.

Figura 10 – Big blue derrota Garry Kasparov

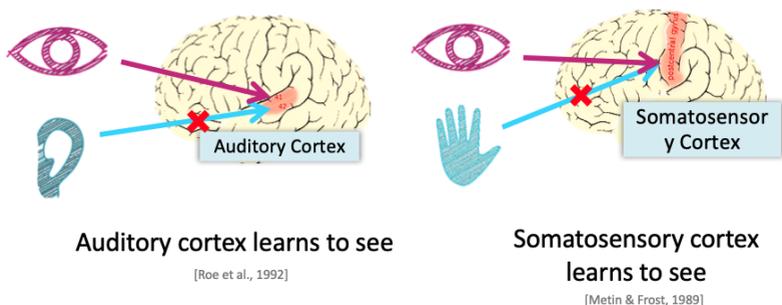


Fonte: The games that helped AI evolve (IBM), Foto de Tom Mihalek (1996)

A hipótese de "One Learning Algorithm" (um único algoritmo de aprendizado) propõe que um único algoritmo suficientemente geral pode ser adaptado para resolver uma ampla variedade de problemas de inteligência artificial, eliminando a necessidade de soluções específicas para cada tarefa.

Essa ideia se inspira na maneira como o cérebro humano utiliza princípios universais para aprender em contextos diversos, presumindo a possibilidade de se alcançar uma generalização matemática da capacidade intelectual humana, referida como inteligência artificial geral (AGI - artificial general intelligence)

Figura 11 – Plasticidade cerebral demonstrada em experimentos



Fonte: Roe et al. (1992) e Metin & Frost (1989).

Como ilustrado na Figura 11, diferentes córtices sensoriais do cérebro humano se adaptaram à atividade de processar informações sensoriais não nativas, demonstrando que áreas específicas do córtex, embora originalmente associadas a modalidades sensoriais específicas, podem reorganizar-se para desempenhar funções distintas quando submetidas a alterações no fluxo sensorial.

No experimento conduzido por Roe et al. (1992), entradas visuais foram redirecionados para o córtex auditivo, normalmente responsável pelo processamento de estímulos sonoros.

Apesar de sua função original, o **córtex auditivo demonstrou a capacidade de interpretar estímulos visuais, "aprendendo a ver"**. Similarmente, Metin e Frost (1989) reenviaram entradas visuais para o córtex somatossensorial, responsável pelo processamento tátil. Este também se adaptou para processar informações visuais, reforçando a ideia de que a arquitetura cortical é amplamente configurável, podendo assumir funções sensoriais alternativas.

Este trabalho dedica-se às aplicações da inteligência artificial especialista, ou "estreita" (narrow AI), cuja finalidade é a resolução de problemas concretos. No âmbito do estudo dessa inteligência, é feita uma subdivisão dos métodos em relação ao processo de treinamento — aprendizado supervisionado e não supervisionado.

2.5 APRENDIZADO SUPERVISIONADO

Aprendizagem supervisionada é fundamentado no treinamento de algoritmos com bases de dados dotadas de rótulos pré-existente: regressão para rótulos numéricos contínuos, e classificação para rótulos discretos, qualitativos.

A generalização matemática de um algoritmo de aprendizado de máquina para classificação, com base no trabalho de Soofi e Awan (2017), pode ser descrita como um processo que mapeia entradas de dados para saídas de categorias predefinidas através de um modelo aprendido a partir de exemplos de treinamento. Matematicamente, este processo é representado como uma função de decisão f que atribui uma entrada x a uma categoria y , baseada em características aprendidas do conjunto de treinamento dos dados.

2.5.1 Problemas de Regressão

Problemas de regressão envolvem a previsão de valores contínuos com base em variáveis independentes. Em outras palavras, a regressão busca estabelecer uma relação funcional entre os atributos de entrada e as saídas, permitindo fazer estimativas ou previsões numéricas.

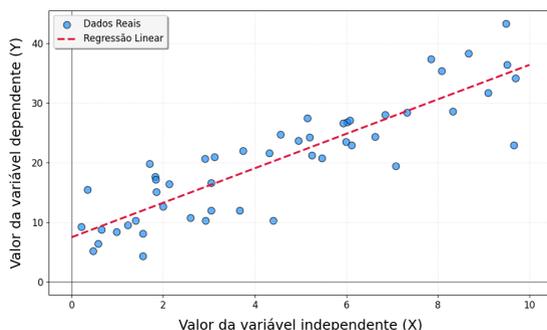
Regressão linear

A regressão linear é uma técnica fundamental do aprendizado de máquina cujo objetivo é estabelecer uma relação linear entre variáveis independentes e dependentes. A função modelo f para regressão linear realiza o mapeamento de uma variável independente x para uma variável dependente y .

$$f_{w,b}(x) = wx + b \quad (1)$$

O treinamento de um modelo de regressão linear é um processo iterativo para determinar os parâmetros (w, b) que melhor se ajustam ao conjunto de dados fornecido, e o processo de ajuste envolve minimizar uma função de custo $J(w, b)$, que mede o erro entre as previsões do modelo e os valores esperados para aquela.

Figura 12 – Ajuste de regressão linear



A minimização de $J(w, b)$ pode ser realizada através do método de *descida de gradiente*, uma técnica iterativa que ajusta os valores de (w, b) para aproximá-los dos valores ótimos. Em cada etapa da descida de gradiente, os parâmetros (w, b) são atualizados, de modo a reduzir

progressivamente o custo $J(w, b)$, até que atinjam um valor mínimo satisfatório.

$$(w, b) \leftarrow (w, b) - \alpha \nabla J(w, b) \quad (2)$$

onde α representa a taxa de aprendizado, e $\nabla J(w, b)$ indica o gradiente da função de custo em relação aos parâmetros. Este método será discutido na seção 2.6.

Após o ajuste linear, o modelo está apto a receber uma nova entrada x e gerar uma previsão $f_{w,b}(x)$ para y , utilizando a expressão definida anteriormente na equação 2. Por fim, a regressão linear permite a realização de previsões baseadas na relação linear aprendida entre as variáveis.

Regressão linear múltipla

A **Regressão linear múltipla** é uma técnica estatística que permite modelar a relação entre uma variável dependente, denotada por y , e várias variáveis independentes x_1, x_2, \dots, x_p . A fórmula geral para a regressão linear múltipla é expressa na equação (3).

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \epsilon \quad (3)$$

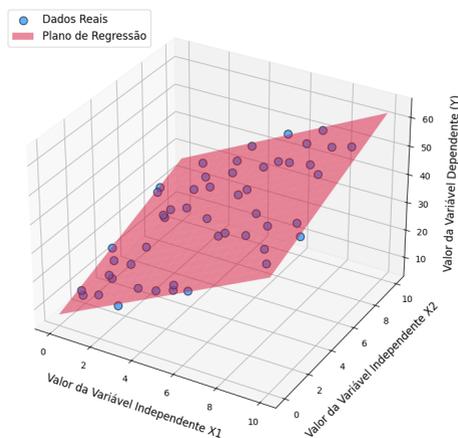
em que:

- $x_i \in \mathbf{R}$, $i = 1, \dots, p$, representam as variáveis independentes
- $\beta_i \in \mathbf{R}$, $i = 0, \dots, p$, denotam os coeficientes de regressão a serem estimados
- $\epsilon \sim \mathcal{N}(0, \sigma^2)$ representa o termo de erro aleatório

Estimar os coeficientes $\beta_0, \beta_1, \dots, \beta_p$ de forma a minimizar a soma dos quadrados dos resíduos ϵ é objetivo de uma regressão linear

múltipla, ajustando a linha ou hiperplano que melhor se adapte aos dados observados.

Figura 13 – Ajuste de regressão linear múltipla



Esses coeficientes indicam a contribuição de cada variável independente na explicação das variações observadas na variável dependente. A regressão linear múltipla é amplamente aplicada para modelar relações envolvendo múltiplas variáveis e para realizar previsões com base nessas relações.

2.5.2 Problemas de classificação

Um classificador pode ser definido definido como uma função

$$\psi : X \rightarrow C,$$

onde X é o espaço das características (geralmente $X = \mathbf{R}^n$) e $C = \{c_1, \dots, c_L\}$ é o conjunto de classes (Valle, 2024)

Problemas de classificação envolvem a atribuição de uma ou mais categorias (rótulos) a cada instância de dados com base em suas

características.

O objetivo do classificador é aprender a relação entre os atributos das instâncias e suas respectivas categorias, permitindo a realização de classificações precisas para novos dados.

A formulação matemática de um algoritmo de aprendizado de máquina para classificação pode ser descrita como um processo que mapeia entradas de dados para saídas de categorias predefinidas através de um modelo aprendido a partir de exemplos de treinamento.

Uma possível representação é uma função de decisão f que atribui uma entrada x a uma categoria y , com base nas características aprendidas dos dados.

A **função de decisão** é definida pela equação (4)

$$f : X \rightarrow Y \quad (4)$$

onde X representa o espaço de entrada (por exemplo, vetores de características) e Y o conjunto de categorias possíveis.

O **modelo de aprendizado** f é aprendido durante o processo de treinamento, visando minimizar uma função de perda L , que mede o erro entre as previsões do modelo e as categorias verdadeiras. A equação (5)

$$L(f(x_i), y_i) \rightarrow \min \quad (5)$$

onde (x_i, y_i) são os pares de entrada-saída do conjunto de treinamento.

O **processo de otimização** envolve ajustar o modelo f para reduzir L usando algoritmos de otimização, como o gradiente descendente. A habilidade do modelo f de prever corretamente as saídas para novos dados não vistos durante o treinamento, é conhecida como **generalização**. Esse aspecto é geralmente avaliado utilizando um conjunto de dados de teste separado dos dados de treinamento.

Para melhorar a capacidade de generalização e evitar o sobreajuste, podem ser aplicadas técnicas de **regularização**, que modificam a função de perda ao incluir um termo de penalidade baseado na complexidade do modelo, ajudando a ajustar o modelo de forma mais generalista a novos dados.

Regressão logística

A **Regressão Logística** é um método estatístico utilizado para modelar a probabilidade de um resultado binário, conforme descrito por James et al. (2013). Em vez de prever diretamente o resultado, esse método calcula a probabilidade de que uma entrada x pertença a uma categoria específica. Para uma entrada x , a probabilidade de pertencer à classe 1 é regida pela equação (6)

$$P(y = 1|x) = \frac{1}{1 + e^{-z}} \quad (6)$$

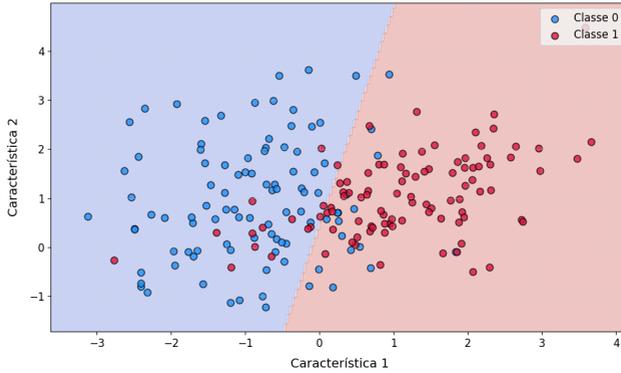
onde $z = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n$ representa uma combinação linear dos preditores x e os coeficientes β . O ajuste do modelo é feito pela maximização da função de verossimilhança, favorecendo coeficientes que discriminem efetivamente entre as classes nas observações de treinamento.

A **fronteira de decisão** na regressão logística se estabelece onde a probabilidade de pertencer a uma das classes é exatamente 50%, ou seja, $P(y = 1|x) = 0.5$

$$\beta_0 + \beta_1 x_1 + \dots + \beta_n x_n = 0 \quad (7)$$

Essa equação (7) define um hiperplano no espaço n -dimensional dos preditores. A orientação e posição da fronteira são determinadas pelos valores dos coeficientes β , sendo que coeficientes maiores em

Figura 14 – Ajuste de regressão logística com base em duas categorias



magnitude indicam uma influência maior de uma característica na probabilidade de pertencer a uma classe.

A **função de custo para a regressão logística**, também chamada de log-verossimilhança negativa, ajusta o modelo aos dados ao quantificar o quão bem o modelo prediz as categorias reais das observações. Para um conjunto de dados com m observações, onde y_i é o rótulo da classe (0 ou 1) e x_i as características da i -ésima observação, a equação (8) função de custo

$$J(\beta) = -\frac{1}{m} \sum_{i=1}^m [y_i \log(\sigma(z_i)) + (1 - y_i) \log(1 - \sigma(z_i))] \quad (8)$$

onde $\sigma(z) = \frac{1}{1+e^{-z}}$ é a função sigmoideal. Essa função, conhecida como entropia cruzada binária, mede a discrepância entre as distribuições de probabilidade reais e as predições. A otimização do modelo visa encontrar os coeficientes β que minimizam $J(\beta)$. Um método comum para essa otimização é o gradiente descendente, em que os coeficientes são iterativamente ajustados de acordo com a atualização descrita na (9)

$$\beta_j := \beta_j - \alpha \frac{\partial J}{\partial \beta_j} \quad (9)$$

onde α é a taxa de aprendizado e $\frac{\partial J}{\partial \beta_j}$ representa o gradiente da função de custo em relação ao coeficiente β_j .

Regressão logística

A **Regressão logística múltipla** estende a regressão logística simples para prever uma resposta binária utilizando múltiplas variáveis preditoras. A fórmula para a regressão logística múltipla é expressa como:

$$\log \left(\frac{p(X)}{1 - p(X)} \right) = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p \quad (10)$$

onde $X = (X_1, \dots, X_p)$ são as variáveis preditoras. Alternativamente, a probabilidade $p(X)$ pode ser expressa como:

$$p(X) = \frac{e^{\beta_0 + \beta_1 X_1 + \dots + \beta_p X_p}}{1 + e^{\beta_0 + \beta_1 X_1 + \dots + \beta_p X_p}} \quad (11)$$

Assim como na regressão logística simples, o método de máxima verossimilhança é utilizado para estimar os coeficientes $\beta_0, \beta_1, \dots, \beta_p$, possibilitando que o modelo ajuste-se de forma adequada aos dados observados.

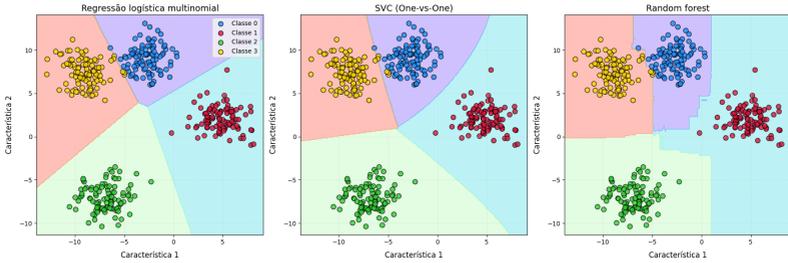
Regressão multiclasse

Para a **classificação de múltiplas classes**, os modelos devem ser capazes de diferenciar entre três ou mais categorias distintas utilizando os dados de entrada.

Ao contrário da classificação binária, em que o objetivo é separar duas classes, a classificação multiclasse exige que o modelo associe cada padrão de entrada a uma dentre várias opções possíveis. classificadores

multinomiais nativos, como a **Regressão Logística Multinomial** (Softmax) ou **Redes Neurais multicamadas** (que serão detalhadas na Seção 2.7 deste capítulo), bem como algoritmos de árvores de decisão (como o Random Forest) e métodos de ensaio (ensemble) que lidam com várias classes de forma direta.

Figura 15 – Algoritmos de classificação multiclasse



SVC (*One-vs-One*)

O método SVC (Support Vector Classifier) para multiclasse One-vs-One (OvO) consiste em ajustar um classificador SVM para cada par de classes (k, l) , $k \neq l$. Cada SVM binária resolve o problema de otimização:

$$\min_{\mathbf{w}, b, \{\xi_i\}} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^{m_{kl}} \xi_i \quad (12)$$

sujeito às restrições:

$$y_i(\mathbf{w}^\top \mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad (13)$$

para as instâncias (\mathbf{x}_i, y_i) pertencentes apenas às classes k e l . Aqui, $C > 0$ é um parâmetro de regularização e ξ_i são variáveis de relaxamento.

Após treinar todos os classificadores binários para cada par de classes, a classe final de um novo ponto \mathbf{x} é decidida por maioria de votos entre todas as comparações par-a-par.

Random Forest

Random Forest é um método de ensemble que combina T árvores de decisão independentes. Cada árvore $h_t(\mathbf{x})$ é treinada em um subconjunto amostral (com substituição) do conjunto de treinamento e usa um subconjunto aleatório de características a cada divisão. A predição final para um ponto \mathbf{x} é dada pela equação **eq:majority**.

$$\hat{y}(\mathbf{x}) = \text{majority_vote}\{h_t(\mathbf{x}) : t = 1, \dots, T\}. \quad (14)$$

Cada árvore de decisão minimiza uma medida de impureza (como a entropia ou o índice Gini) em cada nó para determinar o melhor corte de divisão das características e particionar o espaço de entrada em regiões homogêneas em relação às classes.

Softmax

C. M. Bishop (2006) define a regressão softmax como a generalização da regressão logística para problemas de classificação multiclasse. Enquanto a regressão logística tradicional se concentra em distinguir entre duas classes, a regressão softmax estende essa ideia para casos em que existem K classes ($K \geq 3$), quando cada classe k possui um conjunto de parâmetros (\mathbf{w}_k, b_k) , onde $\mathbf{w}_k \in \mathbf{R}^d$ e $b_k \in \mathbf{R}$.

Dado um vetor de características $\mathbf{x} \in \mathbf{R}^d$, a probabilidade de a instância \mathbf{x} pertencer à classe k (para $k = 1, \dots, K$) é modelada pela função softmax:

$$P(Y = k | \mathbf{x}) = \frac{\exp(\mathbf{w}_k^\top \mathbf{x} + b_k)}{\sum_{j=1}^K \exp(\mathbf{w}_j^\top \mathbf{x} + b_j)}. \quad (15)$$

A função softmax garante que $P(Y = k | \mathbf{x}) \geq 0$ para todo k e que $\sum_{k=1}^K P(Y = k | \mathbf{x}) = 1$, caracterizando uma distribuição de probabilidade sobre as classes.

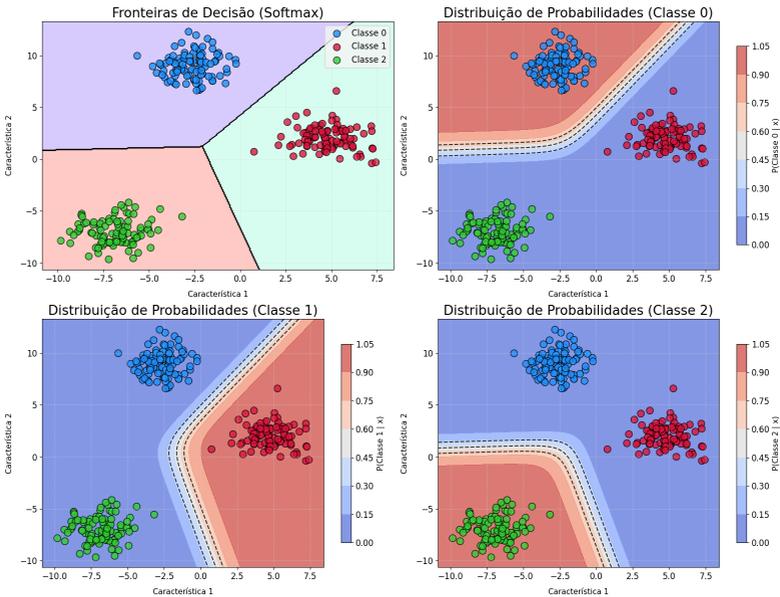


Figura 16 – Softmax para classificação de 4 clusters com duas características

O treinamento do modelo é conduzido através da maximização da verossimilhança do conjunto de treinamento ((19)). Dado um conjunto de treinamento $\{(\mathbf{x}_i, y_i)\}_{i=1}^m$, onde $y_i \in \{1, \dots, K\}$ indica a classe verdadeira da instância \mathbf{x}_i , a função de custo é apresentada na expressão (16)

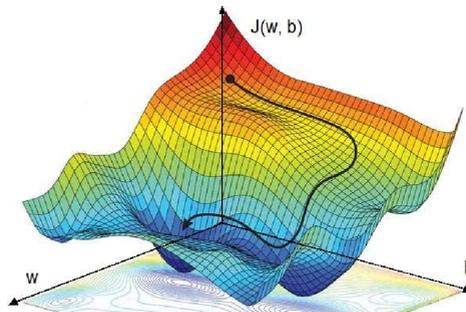
$$J(\{\mathbf{w}_k, b_k\}_{k=1}^K) = - \sum_{i=1}^m \sum_{k=1}^K \mathbf{I}(y_i = k) \log P(Y = k | \mathbf{x}_i), \quad (16)$$

tal que \mathbf{I} é a função indicadora. Este processo de otimização ajusta os parâmetros $\{\mathbf{w}_k, b_k\}$ de modo que a probabilidade da classe correta seja maximizada para cada instância de treinamento.

2.6 DESCIDA DE GRADIENTE

O método da **descida de gradiente** consiste em passos iterativos para ajustar os parâmetros (w, b) , com o objetivo de minimizar progressivamente o valor do custo $J(w, b)$. Em cada etapa do processo, monitora-se o progresso calculando o custo $J(w, b)$ conforme os valores de (w, b) são atualizados.

Figura 17 – Visualização da descida de gradiente



Fonte: Patlatzoglou (2023)

Para um modelo de regressão linear com uma variável, a **função de custo** $J(w, b)$, definida como:

$$J(w, b) = \frac{1}{2m} \sum_{i=0}^{m-1} \left(f_{w,b}(x^{(i)}) - y^{(i)} \right)^2 \quad (17)$$

Onde m representa o número de exemplos de treinamento, $f_{w,b}(x^{(i)})$ é a previsão do modelo para o exemplo $x^{(i)}$, e $y^{(i)}$ é o valor observado.

Para a regressão linear com uma variável, a **previsão do modelo** $f_{w,b}$ para um exemplo $x^{(i)}$ é representada pela função polinomial de primeiro grau (18)

$$f_{w,b}(x^{(i)}) = wx^{(i)} + b \quad (18)$$

Esta é a equação de uma linha reta, onde w representa a inclinação e b o intercepto. Ao ajustar esses parâmetros, busca-se minimizar o valor de $J(w, b)$, permitindo que o modelo produza previsões mais precisas com base nos dados observados.

A **função de custo** na regressão logística, também chamada de log-verossimilhança negativa, quantifica a precisão das previsões em relação aos resultados reais, definida conforme a expressão (19)

$$J(\beta) = -\frac{1}{m} \sum_{i=1}^m [y_i \log(\sigma(z_i)) + (1 - y_i) \log(1 - \sigma(z_i))] \quad (19)$$

o parâmetro $\sigma(z) = \frac{1}{1+e^{-z}}$ representa a função sigmoideal, e $z_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_n x_{in}$ é a combinação linear dos coeficientes β e das características x_i .

Para ajustar os coeficientes, calcula-se o **gradiente da função de custo** por meio da (20)

$$\nabla J(\beta) = \frac{1}{m} \sum_{i=1}^m (\sigma(z_i) - y_i) x_i \quad (20)$$

Esse gradiente indica a direção de maior crescimento da função de custo, e o algoritmo ajusta os coeficientes em direção oposta ao gradiente para minimizar $J(\beta)$.

No **algoritmo de descida de gradiente**, os coeficientes são atualizados de acordo com a equação (21)

$$\beta := \beta - \alpha \nabla J(\beta) \quad (21)$$

Com α representando a taxa de aprendizado, governando o tamanho do passo em direção ao mínimo da função de custo. A convergência do algoritmo ocorre quando a mudança na função de custo ou nos coeficientes entre as iterações se torna suficientemente pequena. A figura 18 ilustra o caminho da descida de gradiente para uma função cônica modular com taxa de aprendizado de 0.1, máximo de 1000 iterações e otimizador Adam.

2.6.1 Overfitting

Overfitting é um fenômeno no aprendizado de máquina em que um modelo treinado se adapta excessivamente aos dados de treinamento, comprometendo seu desempenho em novos dados. Esse problema ocorre quando o modelo apresenta um erro de treinamento baixo, mas um erro de generalização elevado, indicando que ele não é capaz de generalizar bem. Dado um **modelo de aprendizado** f parametrizado por θ que minimiza uma função de perda L nos dados de treinamento - a equação (23) define sua função de perda para o conjunto de treinamento.

$$L(\theta) = \frac{1}{n} \sum_{i=1}^n \ell(f(x_i, \theta), y_i) \quad (22)$$

Sendo que (x_i, y_i) representa os dados de treinamento, ℓ é a função de perda individual e n é o número de exemplos no conjunto de treinamento.

O **erro de generalização** mede a expectativa da função de perda sobre uma nova amostra e é expresso como (23)

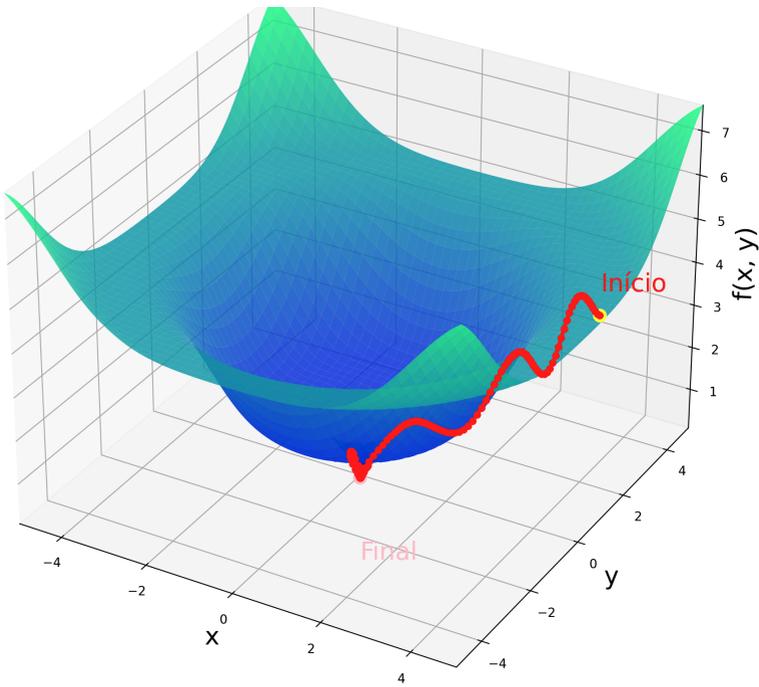


Figura 18 – Visualização da descida de gradiente com otimizador adam

$$E_{(x,y) \sim D}[\ell(f(x, \theta), y)] \quad (23)$$

onde D representa a distribuição dos dados. O overfitting pode ser causado por uma complexidade excessiva do modelo (como muitos parâmetros ou alta flexibilidade) ou por um número insuficiente de exemplos de treinamento, o que impede uma representação adequada da distribuição dos dados reais.

Para mitigar o **overfitting**, diversas abordagens têm sido propostas na literatura, cada uma com características específicas que

buscam melhorar a capacidade de generalização do modelo. Entre essas soluções, destacam-se:

- **Regularização (L1, L2 e dropout):** A regularização L1 (Lasso) adiciona um termo de penalidade baseado na soma dos valores absolutos dos pesos, promovendo a esparsidade do modelo e a seleção automática de variáveis que impactam no resultado. A regularização L2 (Ridge) penaliza a soma dos quadrados dos pesos, reduzindo a magnitude dos parâmetros e controlando a complexidade do modelo. O método de dropout, por sua vez, atua durante o treinamento, desativando aleatoriamente neurônios em cada iteração, o que força a rede a aprender representações mais significativas (Srivastava et al., 2014).
- **Validação cruzada:** Esta técnica divide os dados de treinamento em múltiplos subconjuntos (*folds*), utilizando cada um deles como conjunto de validação em diferentes iterações. A validação cruzada, especialmente a técnica de *k-fold*, permite avaliar a performance do modelo de forma consistente, diminuindo o risco de ajustes específicos a apenas uma parte dos dados (Hastie et al., 2009).
- **Redução da dimensionalidade e seleção de características:** Métodos como Análise de Componentes Principais (PCA) e algoritmos baseados em informação mútua ajudam a identificar e remover variáveis irrelevantes ou redundantes nos dados de entrada, diminuindo a complexidade do modelo e, consequentemente, o risco de overfitting. Além disso, a seleção de características pode ser guiada por técnicas supervisionadas, como *Recursive Feature Elimination* (RFE), otimizando o conjunto de variáveis com maior poder preditivo (Guyon e Elisseeff, 2003).

Essas estratégias, foram aplicadas em conjunto para construir um modelo mais generalizável, mantendo o equilíbrio entre a complexidade e a capacidade de previsão. Sem regularização, a **função de custo original** é tipicamente a soma das perdas calculadas sobre o conjunto de treinamento:

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m \ell(f(x_i, \theta), y_i) \quad (24)$$

onde m representa o número de exemplos de treinamento.

A **regularização** adiciona um termo de penalidade à função de custo para reduzir valores extremos dos parâmetros do modelo. Esse termo de regularização pode ser expresso como:

$$R(\theta) = \lambda \|\theta\|^p \quad (25)$$

onde λ é o parâmetro de regularização, e $\|\theta\|^p$ é a norma p dos parâmetros θ , comumente escolhendo-se $p = 1$ (Lasso) ou $p = 2$ (Ridge).

Assim, a **função de custo regularizada** final é:

$$J_{\text{reg}}(\theta) = J(\theta) + R(\theta) \quad (26)$$

onde $J(\theta)$ representa a função de custo original, $R(\theta)$ é o termo de regularização que penaliza a complexidade do modelo, e λ é o parâmetro de regularização que controla o peso dessa penalidade.

Esse ajuste tem o objetivo de equilibrar a adaptação aos dados de treinamento com a simplicidade do modelo, minimizando o risco de overfitting e promovendo melhor desempenho em dados não vistos. A descida de gradiente com regularização ajustam iterativamente os parâmetros do modelo de modo a incluir uma penalidade que restringe sua complexidade, os parâmetros do modelo são atualizados de acordo com a 27:

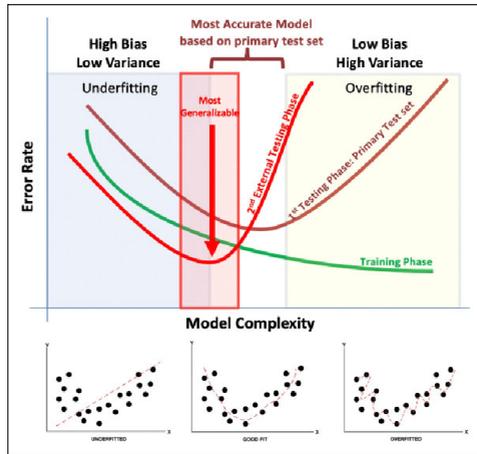


Figura 19 – Ponto ótimo entre viés e variância Rashidi et al. (2019)

$$\theta := \theta - \alpha (\nabla J(\theta) + \lambda \nabla R(\theta)) \quad (27)$$

α é a taxa de aprendizado, e ∇ o gradiente da função de custo e do termo de regularização em relação aos parâmetros θ . Esse ajuste iterativo permite que o modelo alcance uma solução ótima que evita a complexidade excessiva e, portanto, o overfitting.

A **convergência** do algoritmo é influenciada pela escolha de α e λ . Uma taxa de aprendizado α muito alta pode causar divergência, enquanto um λ excessivo pode resultar em um modelo excessivamente simplificado, perdendo capacidade de ajuste aos dados. Portanto, uma escolha adequada desses parâmetros é essencial para garantir a eficácia do modelo e a qualidade da solução final.

2.7 REDES NEURAIS

Redes neurais são construídas a partir de um paradigma de aprendizado e processamento de informações inspirado no funcionamento do cérebro humano.

Constituem-se de nós, ou neurônios artificiais, interligados que operam cooperativamente para resolver problemas específicos (LeCun et al., 2015).

Este modelo é eficaz em tarefas de reconhecimento de padrões e classificação, devido à sua capacidade de aprender diretamente a partir dos dados. A estrutura básica de uma rede neural inclui uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída.

Os neurônios nas camadas ocultas processam os valores recebidos da camada anterior através de uma combinação linear, seguida por uma função de ativação não linear, que permite ao modelo capturar relações complexas de diferentes entradas de dados.

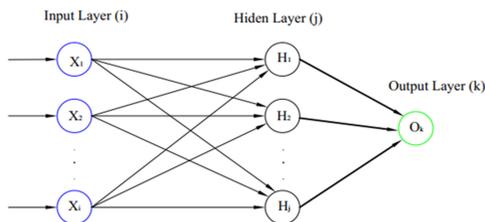


Figura 20 – Rede neural de múltiplas camadas (Neural Network, an overview, ScienceDirect 2023)

No processo de aprendizado das redes neurais, ajustam-se os pesos sinápticos para minimizar a função de custo, como o erro quadrático médio. Esse ajuste é realizado geralmente pelo algoritmo de retropropagação (backpropagation), aliado da descida de gradiente para refinar iterativamente os pesos e reduzir o erro. As **funções de**

ativação, introduzem a não-linearidade necessária para que a rede aprenda padrões complexos.

Uma rede neural *feedforward* típica é composta por três tipos de camadas: a camada de entrada, várias camadas ocultas e a camada de saída. Esses componentes são definidos conforme a tabela ??.

Camada	Descrição
Camada de Entrada	Recebe o vetor de entrada \mathbf{x}
Camadas Ocultas	Cada camada processa a saída da camada anterior $a^{(l)}$ usando uma combinação linear dos pesos $W^{(l)}$ e do viés $b^{(l)}$, seguida pela aplicação de uma função de ativação $f \mathbf{a}^{(l)} = f(\mathbf{W}^{(l)}\mathbf{a}^{(l-1)} + \mathbf{b}^{(l)})$
Camada de Saída	Gera a saída final da rede \mathbf{y}

Tabela 5 – Estrutura das Camadas de uma Rede Neural

A camada de saída, ou camada de ativação, realiza uma previsão com base na função logística de log-verossimilhança negativa 19, levando em conta o resultado obtido através de todos os parâmetros de pesos, vieses e operações não lineares realizadas pelas camadas ocultas de neurônios.

2.7.1 Propagação para frente (forward propagation)

Na propagação para frente, a informação flui da camada de entrada através das camadas ocultas até a camada de saída. Para cada camada l , o processo é descrito pelas equações (28) e (29).

$$\mathbf{z}^{(l)} = \mathbf{W}^{(l)}\mathbf{a}^{(l-1)} + \mathbf{b}^{(l)} \quad (28)$$

$$\mathbf{a}^{(l)} = f(\mathbf{z}^{(l)}) \quad (29)$$

Figura 21 – Unidade de saída, adaptado dos slides de Eric Eaton e Andrew Ng

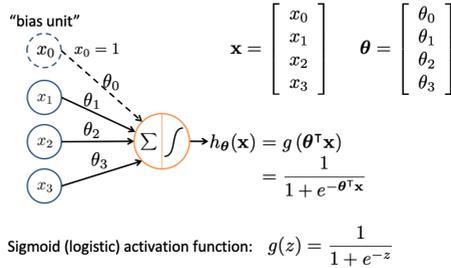


Figura 22 – Adaptado dos slides de Eric Eaton e Andrew Ng

onde $\mathbf{z}^{(l)}$ é o vetor linearizado de entrada para a camada l e f é a função de ativação aplicada. Este processo permite que a rede propague a informação camada por camada, permitindo o aprendizado de padrões complexos a partir dos dados.

2.7.2 Retropropagação (backpropagation)

A retropropagação é um algoritmo utilizado para calcular os gradientes dos pesos, permitindo a atualização dos parâmetros na rede neural com o objetivo de minimizar a função de custo J . Essa função de custo mede o erro entre a saída prevista \mathbf{y} e a saída real \mathbf{y}_{real} . Na camada de saída L , o **Cálculo do Gradiente** em relação a $\mathbf{z}^{(L)}$ é realizado como:

$$\delta^{(L)} = \frac{\partial J}{\partial \mathbf{z}^{(L)}} = \frac{\partial J}{\partial \mathbf{a}^{(L)}} \odot f'(\mathbf{z}^{(L)}) \quad (30)$$

\odot representa a multiplicação elemento a elemento, e $f'(\mathbf{z}^{(L)})$ é a derivada da função de ativação na camada de saída. A **Propagação do Gradiente para Camadas Anteriores**, é aplicada para

cada camada l anterior, o gradiente é propagado de forma recursiva, conforme a equação (31).

$$\delta^{(l)} = (\mathbf{W}^{(l+1)T} \delta^{(l+1)}) \odot f'(\mathbf{z}^{(l)}) \quad (31)$$

Esse passo permite que o gradiente da função de custo se propague para trás através das camadas, ajustando-se de acordo com os pesos e a função de ativação de cada camada. Finalmente, os pesos $\mathbf{W}^{(l)}$ e vieses $\mathbf{b}^{(l)}$ são atualizados de acordo com a taxa de aprendizado η , utilizando as equações (32) (??)

$$\mathbf{W}^{(l)} = \mathbf{W}^{(l)} - \eta \delta^{(l)} (\mathbf{a}^{(l-1)})^T \quad (32)$$

$$\mathbf{b}^{(l)} = \mathbf{b}^{(l)} - \eta \delta^{(l)} \quad (33)$$

Este processo é repetido para cada exemplo de treinamento ou lote de treinamento, ao longo de várias épocas, até que a rede convirja para um estado em que o erro de previsão seja minimizado.

2.8 REDES NEURAI CONVOLUCIONAIS

Redes neurais convolucionais (CNNs) são um tipo especializado de rede neural projetado especialmente para processar dados que possuem uma estrutura de grade, como imagens. Essas redes são altamente eficazes em tarefas de visão computacional, como classificação de imagens e detecção de objetos, devido à sua capacidade de capturar características locais e hierárquicas nos dados.

O reconhecimento de imagens é uma das aplicações mais comuns e impactantes de redes neurais profundas. Este processo envolve a classificação de imagens em categorias predefinidas com base nos recursos visuais aprendidos durante o treinamento da rede.

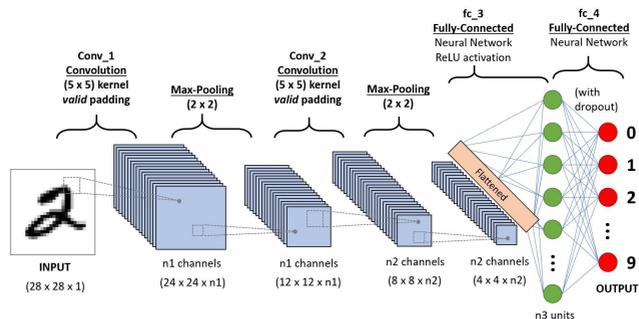


Figura 23 – Típica Arquitetura de CNN (Nnalytics Vidhya, 2020)

A principal inovação das CNNs é a camada de convolução. Essa camada aplica uma série de filtros (também chamados de kernels) a pequenas regiões da entrada, realizando convoluções que extraem características específicas, como bordas, texturas e padrões, em diferentes níveis de abstração. Essas características são, então, combinadas e aprendidas por camadas posteriores da rede para fazer previsões.

Uma rede neural convolucional é composta por camadas de operações distintas, incluindo convoluções, pooling e camadas totalmente conectadas. A camada de convolução aplica os filtros à entrada e gera mapas de características. A camada de pooling reduz a dimensionalidade dos mapas de características, preservando as informações mais importantes, e as camadas totalmente conectadas recebem as características extraídas pelas camadas anteriores e as usam para fazer previsões.

2.8.1 Arquitetura da Rede

A **camada convolucional** é um componente fundamental nas Redes Neurais Convolucionais (CNNs), pois aplica filtros sobre as matrizes de entrada para gerar mapas de características. Esse processo

é representado pela seguinte operação de convolução:

$$\mathbf{S}(i, j) = (\mathbf{K} * \mathbf{X})(i, j) = \sum_m \sum_n \mathbf{K}(m, n) \cdot \mathbf{X}(i - m, j - n) \quad (34)$$

em que \mathbf{X} é a matriz de entrada, \mathbf{K} é o filtro (ou kernel), e \mathbf{S} é o mapa de características resultante.

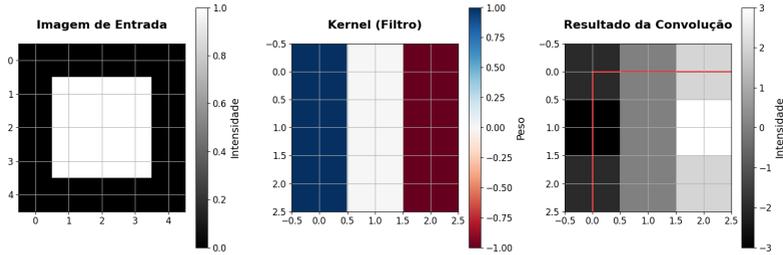


Figura 24 – Procedimento de convolução

A **Camada de Pooling** tem a função de reduzir a dimensionalidade espacial dos mapas de características gerados pela camada convolucional, retendo informações essenciais e reduzindo o risco de overfitting. A operação de pooling mais comum é o *max pooling*, definida por:

$$\mathbf{P}(i, j) = \max(\mathbf{X}[i : i + k, j : j + k]) \quad (35)$$

onde \mathbf{P} é o mapa de saída, \mathbf{X} é o mapa de entrada, e k representa o tamanho da janela de pooling.

Após as camadas convolucionais e de pooling, as características extraídas são achatadas em um vetor e passadas para camadas **Camada Totalmente Conectada**, que realizam uma combinação linear dos dados:

$$\mathbf{y} = \mathbf{W}\mathbf{x} + \mathbf{b} \quad (36)$$

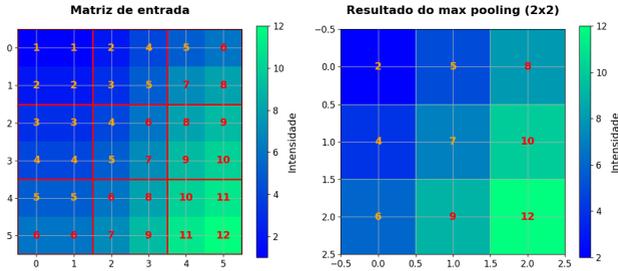


Figura 25 – Operação de max pooling com filtro (2x2)

onde \mathbf{y} é o vetor de saída, \mathbf{W} é a matriz de pesos, \mathbf{x} é o vetor de entrada achatado, e \mathbf{b} é o vetor de vies.

As **camadas de ativação** aplicam uma função não-linear, elemento a elemento, aos resultados das camadas anteriores. Uma função de ativação comumente utilizada é a ReLU (Unidade Linear Retificada), definida por:

$$f(x) = \max(0, x) \quad (37)$$

As camadas de uma rede neural convolucional são projetadas para extrair e transformar características relevantes das matrizes de entrada, possibilitando a realização de tarefas complexas, como reconhecimento de padrões e classificação de imagens.

2.9 APRENDIZADO NÃO SUPERVISIONADO

Aprendizado de máquina não supervisionado é uma classe de algoritmos de aprendizado de máquina que opera sem a necessidade de rótulos previamente definidos, sendo capaz de identificar padrões e estruturas intrínsecas nos dados (Hinton e Sejnowski, 2018). Diferente do aprendizado supervisionado, onde os modelos são treinados com entradas associadas a saídas conhecidas, o aprendizado não supervi-

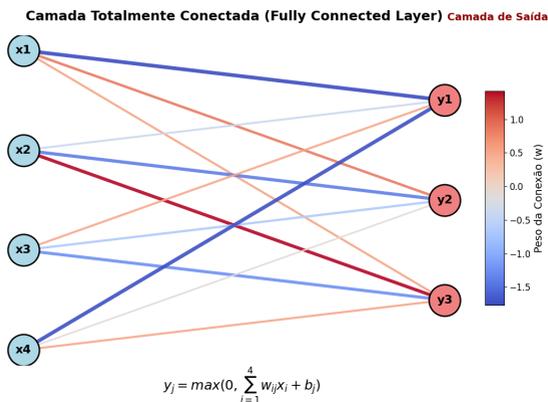


Figura 26 – Camada totalmente conectada (exemplo para 4 neurônios com ativação ReLU)

onado busca modelar a distribuição dos dados ou encontrar subgrupos dentro dos dados.

Uma das principais técnicas de aprendizado não supervisionado, como abordado na revisão de Greene et al. (2008), é a análise de agrupamento (clustering), que visa dividir o conjunto de dados em grupos baseados na similaridade dos dados. K-means e agrupamento hierárquico são exemplos populares de algoritmos de clustering. Outra técnica importante é a redução de dimensionalidade, que reduz o número de variáveis aleatórias sob consideração, através de métodos como Análise de Componentes Principais (PCA) e t-SNE, facilitando a visualização e otimização dos dados para melhor análise.

Modelos generativos, como as Máquinas de Boltzmann Restritas (RBMs) e os Autoencoders Variacionais (VAEs), também introduzidos pelo trabalho de LeCun et al. (2015) na aplicação para redução de dimensionalidade e aprendizado de atributos específicos. Aplicações de aprendizado não supervisionado incluem detecção de anomalias,

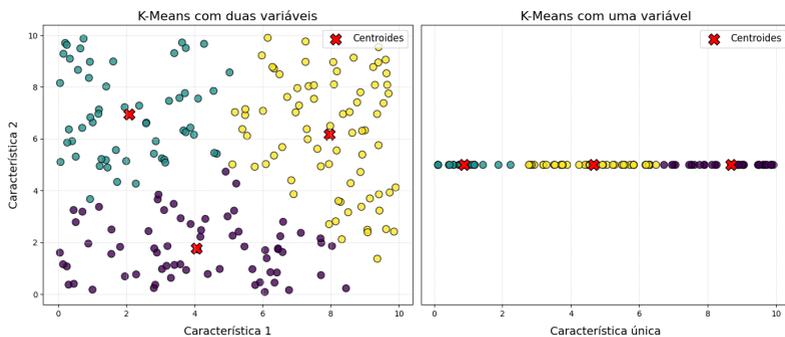


Figura 27 – Agrupamento k-means

segmentação de clientes e sistemas de recomendação, onde padrões ocultos nos dados são explorados sem exemplos explícitos do que constitui uma categoria válida. Tal modelo foi utilizado neste trabalho para o trabalho de detecção de comportamentos estruturais anômalos sem a necessidade de rotulagem.

2.9.1 Autoencoders para detecção de Danos

Autoencoders são redes neurais utilizadas para aprender representações de dados de forma não supervisionada, conforme a definição de Bank et al. (2020) - são empregados em detecção de danos por sua capacidade de reconstruir entradas normais e identificar desvios que possam indicar anomalias ou danos.

Um autoencoder é composto por duas partes principais:

- **Codificador:** Transforma a entrada x em uma representação latente z .
- **Decodificador:** Reconstrói a entrada a partir de z , gerando \hat{x} .

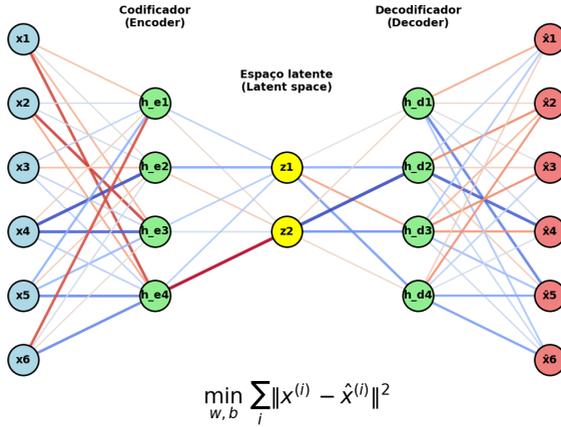


Figura 28 – Representação de um autoencoder

Função de Codificação

$$z = f(x) = \sigma(Wx + b) \tag{38}$$

Onde σ é uma função de ativação não-linear, W são os pesos do codificador, b é o vetor de viés, e x é a entrada.

Função de Decodificação

$$\hat{x} = g(z) = \sigma(W'z + b') \tag{39}$$

Onde W' e b' são os parâmetros do decodificador, e z é a representação latente.

Função de Perda

$$L(x, \hat{x}) = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (40)$$

Onde n é o número de amostras ou dimensões de x . Esta função de perda (erro quadrático médio) minimiza a diferença entre a entrada original e sua reconstrução.

Aplicação na Detecção de Danos

As diferenças entre a entrada x e a saída reconstruída \hat{x} podem indicar a presença de danos. A função de perda pode ser ajustada para ser mais sensível a características de danos:

$$L_{damage}(x, \hat{x}) = \lambda \cdot L(x, \hat{x}) + (1 - \lambda) \cdot L_{specific}(x, \hat{x}) \quad (41)$$

Onde λ é um parâmetro para balancear a importância entre a reconstrução geral e as características específicas de danos, e $L_{specific}$ é uma função de perda projetada para capturar aspectos particulares dos dados relacionados a danos.

3 COLETA DE DADOS

3.1 INTERAÇÃO VEÍCULO-ESTRUTURA

A interação veículo-ponte (do inglês, vehicle-bridge interaction, VBI) ocorre quando um veículo em movimento atravessa uma ponte, esse fenômeno tem sido estudado há décadas, com trabalhos fundamentais de Fryba (1972) e Y.-B. Yang et al. (2004).

Softwares como o VBI-2D de Cantero (2024) surgem como uma forma de testar hipóteses de monitoramento estrutural indireto (ou “vehicle scanning method”), analisando respostas de veículos ao atravessar pontes, como é o caso deste trabalho, de forma similar ao trabalho de Sarwar e Cantero (2021), onde respostas de veículos foram processadas via autoencoder para detectar características sensíveis a danos.

3.1.1 Fundamentos da Modelagem

O problema de interação veículo-ponte descreve o comportamento conjunto de uma ponte e um veículo em movimento, considerando possíveis irregularidades na superfície de deslocamento. Na forma mais simples, o problema pode ser definido como mostrado na 29.

O veículo, representado por um oscilador simples, consiste de uma massa m_V movendo-se com velocidade uniformemente acelerada $v(t)$, conectado à superfície da estrada $h(t)$ no ponto de contato por um sistema de mola e amortecedor, caracterizado pela rigidez k_V e amortecimento viscoso c_V .

$$v(t) = v_0 + a \cdot t = v_t \quad (42)$$

A deformação da viga pode ser expressa conforme a Eq. 43,

Figura 29 – Representação do VBI-2D

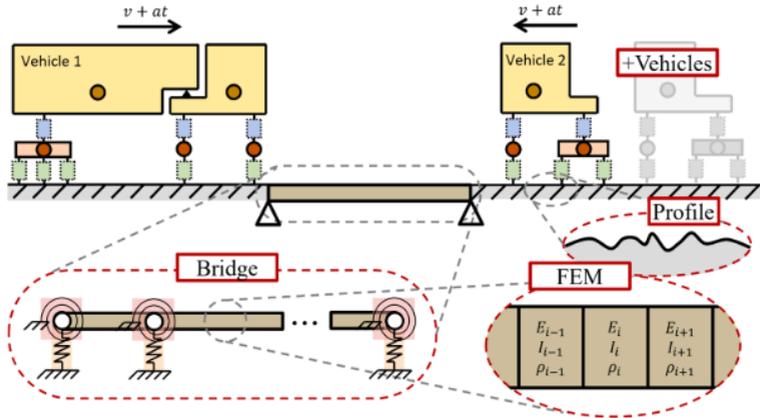


Fig. 1. Graphical description of VBI-2D simulation software.

Fonte: CANTERO, 2023

como uma série infinita das formas modais Φ_i multiplicadas por suas coordenadas generalizadas correspondentes η_i . Esta série pode ser aproximada considerando apenas os n primeiros modos.

$$y_B(x, t) = \sum_{i=1}^{\infty} \Phi_i(x) \eta_i(t) \approx \sum_{i=1}^n \Phi_i(x) \eta_i(t) \quad (43)$$

Com essas definições, é possível formular as equações de movimento do sistema acoplado. Estas $N = n + 1$ equações podem ser reorganizadas em um sistema de equações diferenciais de segunda ordem expresso em forma matricial (Eq. 44) para o vetor de variáveis desconhecidas (Eq. 45).

$$M\ddot{q} + C\dot{q} + Kq = F \quad (44)$$

$$q = \left(y_V \quad \eta_1 \quad \eta_2 \quad \dots \quad \eta_n \right)^T \quad (45)$$

Matrizes do Sistema

As matrizes do sistema na Eq. (3), considerando os primeiros n modos de vibração da viga, são definidas como segue:

$$M = \begin{pmatrix} m_V & 0 & 0 & \dots & 0 \\ 0 & m_B & 0 & \dots & 0 \\ 0 & 0 & m_B & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & m_B \end{pmatrix} \quad (1)$$

$$C = c_V \begin{pmatrix} 1 & -\Phi_1 & -\Phi_2 & \dots & -\Phi_n \\ -\Phi_1 & \Phi_1^2 & \Phi_1\Phi_2 & \dots & \Phi_1\Phi_n \\ -\Phi_2 & \Phi_2\Phi_1 & \Phi_2^2 & \dots & \Phi_2\Phi_n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ -\Phi_n & \Phi_n\Phi_1 & \Phi_n\Phi_2 & \dots & \Phi_n^2 \end{pmatrix} \quad (2)$$

A matriz de rigidez K é dada por $K = K_k + K_c$, onde:

$$K_k = k_V \begin{pmatrix} 1 & -\Phi_1 & -\Phi_2 & \dots & -\Phi_n \\ -\Phi_1 & m_B\omega_{B,1}^2 + \Phi_1^2 & \Phi_1\Phi_2 & \dots & \Phi_1\Phi_n \\ -\Phi_2 & \Phi_2\Phi_1 & m_B\omega_{B,2}^2 + \Phi_2^2 & \dots & \Phi_2\Phi_n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ -\Phi_n & \Phi_n\Phi_1 & \Phi_n\Phi_2 & \dots & m_B\omega_{B,n}^2 + \Phi_n^2 \end{pmatrix} \quad (3)$$

$$K_c = v_i c_V \begin{pmatrix} 0 & -\Phi'_1 & -\Phi'_2 & \cdots & -\Phi'_n \\ 0 & \Phi_1 \Phi'_1 & \Phi_1 \Phi'_2 & \cdots & \Phi_1 \Phi'_n \\ 0 & \Phi_2 \Phi'_1 & \Phi_2 \Phi'_2 & \cdots & \Phi_2 \Phi'_n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & \Phi_n \Phi'_1 & \Phi_n \Phi'_2 & \cdots & \Phi_n \Phi'_n \end{pmatrix} \quad (4)$$

O vetor de forças F é definido por:

$$F = \begin{pmatrix} k_V \dot{h} + c_V \dot{h} \\ (m_V g - k_V h - c_V \dot{h}) \Phi_1 \\ (m_V g - k_V h - c_V \dot{h}) \Phi_2 \\ \vdots \\ (m_V g - k_V h - c_V \dot{h}) \Phi_n \end{pmatrix} \quad (5)$$

de forma que $\Phi_i = \Phi_i(x_V, t)$ representa o valor do i -ésimo modo de vibração na posição do veículo x_V , e Φ'_i é sua derivada espacial primeira. Além disso, g representa a aceleração da gravidade e \dot{h} a derivada temporal do perfil da estrada.

A equação de movimento do sistema massa-mola-amortecimento do veículo pode ser descrita de acordo com a 46.

$$m_V \ddot{y}_V(t) + c_V [\dot{y}_V(t) - \dot{h}(t)] + k_V [y_V(t) - h(t)] = 0. \quad (46)$$

Dessa forma, m_V representa a massa do veículo, $y_V(t)$ corresponde ao deslocamento vertical da massa do veículo, e $h(t)$ denota o deslocamento vertical da superfície da estrada. Além disso, c_V constitui o coeficiente de amortecimento viscoso, enquanto k_V representa a rigidez da mola.

A derivada temporal do deslocamento, $\dot{y}_V(t)$, representa a velocidade vertical do veículo, enquanto $\ddot{y}_V(t)$ é a aceleração vertical. Analogamente, $\dot{h}(t)$ é a taxa de variação da superfície da estrada. A

força de mola, $k_V[y_V(t) - h(t)]$, atua sempre no sentido de restaurar o veículo à posição de equilíbrio, e a força de amortecimento, $c_V[\dot{y}_V(t) - \dot{h}(t)]$, dissipa energia do sistema, reduzindo as oscilações.

Dessa forma, o sistema modela o comportamento dinâmico vertical de um veículo em movimento sobre uma superfície com irregularidades, permitindo a análise e previsão das respostas do sistema sob diversas condições de perfil de pavimento.

A equação do movimento para o conjunto veículo-ponte pode ser expressa em termos de vetores de aceleração \ddot{X} , velocidade \dot{X} , deslocamento X , força F , massa M , rigidez K_{ij} e amortecimento C_{ij} .

$$\begin{bmatrix} \mathbf{M}_v & \mathbf{0} \\ \mathbf{0} & \mathbf{M}_b \end{bmatrix} \begin{Bmatrix} \ddot{\mathbf{X}}_v \\ \ddot{\mathbf{X}}_b \end{Bmatrix} + \begin{bmatrix} \mathbf{C}_v & \mathbf{C}_{vb} \\ \mathbf{C}_{bv} & \mathbf{C}_b \end{bmatrix} \begin{Bmatrix} \dot{\mathbf{X}}_v \\ \dot{\mathbf{X}}_b \end{Bmatrix} + \begin{bmatrix} \mathbf{K}_v & \mathbf{K}_{vb} \\ \mathbf{K}_{bv} & \mathbf{K}_b \end{bmatrix} \begin{Bmatrix} \mathbf{X}_v \\ \mathbf{X}_b \end{Bmatrix} = \begin{Bmatrix} \mathbf{F}_v \\ \mathbf{F}_b \end{Bmatrix}. \quad (47)$$

3.2 VBI-2D

Os sinais utilizados no estudo foram produzidos com o uso do software VBI-2D desenvolvido por Cantero (2024), viabilizando a análise das respostas de uma série de interações dinâmicas de um conjunto veículo-ponte, levando em consideração irregularidades no perfil da estrada e a variabilidade nas propriedades físicas do veículo a cada passagem.

A interação entre o veículo e a ponte é resolvida numericamente através da integração direta com o método de Newmark- β , utilizando procedimentos de simulação iterativa que consideram as deformações e os momentos fletores da estrutura induzidos da massa por unidade de comprimento da viga e do carregamento induzido pelas rodas do veículo.

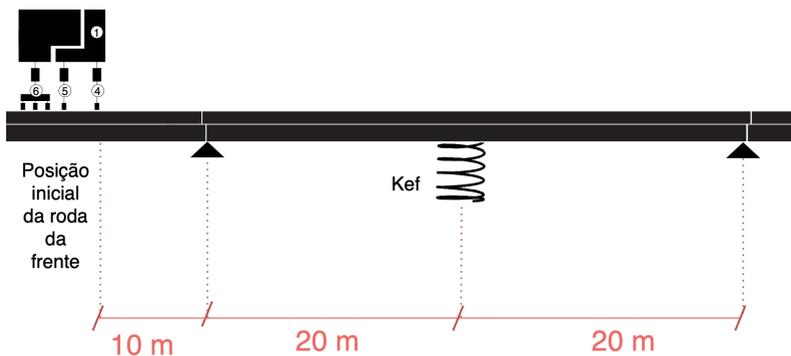
A ponte é representada como uma viga de Euler-Bernoulli com dois apoios fixos nas extremidades e um apoio flexível na posição

central, as propriedades físicas adotadas para as iterações do algoritmo estão descritas na tabela 6.

Tabela 6 – Parâmetros da Viga

Parâmetro	Valor
L_b [m]	40
ρ [kg/m]	18 358
E [Pa]	$3,5 \times 10^{10}$
I [m ⁴]	1,3901
C [%]	3
K_{ef} [Pa]	$3,44 \times 10^8 \times \beta$

Figura 30 – Representação do sistema dinâmico



A posição inicial do veículo é 10 metros antes do início do primeiro vão, e o deslocamento do veículo ao longo da viga é definido em pelo movimento acelerado uniformemente para a direita, conforme Eq. 42, onde a velocidade instantânea do veículo é denotada por v_t .

3.2.1 Descrição das iterações do algoritmo para geração da base de dados

O script executa por um número definido de iterações (`numIterações`), em cada iteração:

- Gera fatores de ruído aleatórios (5 fatores gerais mais 1 fator específico de velocidade)
- Cria um modelo de veículo com estes fatores de ruído
- Configura um perfil de configuração ISO classe A
- Configura propriedades da viga usando β como coeficiente de redução na rigidez do apoio central
- Executa os cálculos usando a função A02 Calculations

Na primeira iteração, são determinados os passos temporais discretizados no domínio do espaço, utilizando a função B11 TimeSpace Discretization, e pré aloca vetores para armazenar dados de aceleração para 4 diferentes graus de liberdade (GDLs 1, 4, 5 e 6), e escreve cinco arquivos CSV contendo os dados de velocidade do veículo, e os dados de aceleração para os graus de liberdade do veículo.

- **Massa (m_{Bi}):** massa total do veículo (incluindo trator, reboque e eixos), que influencia a inércia do conjunto e, consequentemente, a forma como o sistema responde às vibrações.
- **Rigidez da suspensão (k_{Sj}):** parâmetro que quantifica a capacidade da suspensão do veículo em resistir a deformações elásticas, afetando o nível de conforto e estabilidade.
- **Rigidez dos pneus (k_{Tk}):** indica o quanto o pneu se deforma verticalmente sob carga, interferindo na transmissão das irregularidades do solo ao restante do veículo.

Tabela 7 – Faixa de possíveis parâmetros do veículo a cada iteração

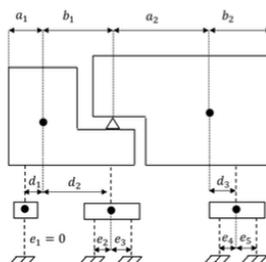
Parâmetro	Min.	Max.	μ	σ
m_{B1} [kg]	4050	4950	4500	10%
m_{B2} [kg]	28305	34595	31450	10%
I_{Bi} [kg · m ²]	4604	16302	10453	10%
k_{Sj} [N/m]	360×10^3	2475×10^3	1325×10^3	10%
c_{Sj} [N · s/m]	900	3300	2000	10%
m_{G1} [kg]	630	770	700	10%
m_{G2} [kg]	990	1210	1100	10%
m_{G3} [kg]	2025	2475	2250	10%
I_{Gj} [kg · m ²]	100	200	167	10%
k_{Tk} [N/m]	1575×10^3	3850×10^3	2625×10^3	10%
c_{Tk} [N · s/m]	0.9×10^4	1.1×10^4	1×10^4	10%
v [m/s]	19	21	20	5%

- **Amortecimento da suspensão** (c_{Sj}): taxa de dissipação de energia vibratória no sistema, definindo quão rapidamente as oscilações são reduzidas após uma perturbação.
- **Velocidade** (v): velocidade longitudinal do veículo, que altera a frequência com que as irregularidades do pavimento são encontradas, influenciando a resposta dinâmica geral.

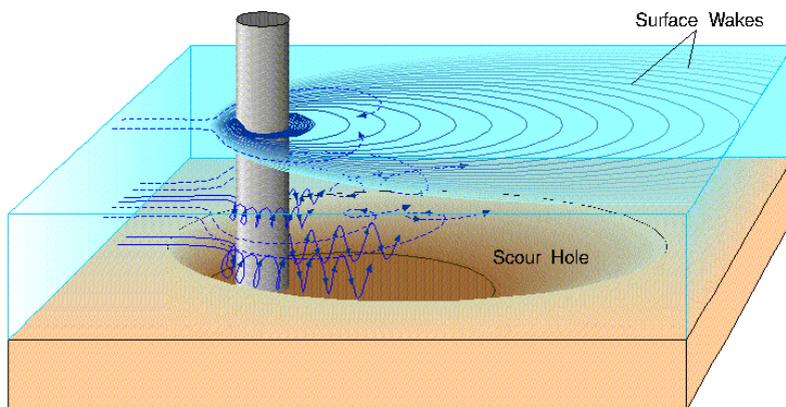
3.2.2 Modelagem da erosão na base das fundações

Erosão refere-se à erosão do solo ao redor das fundações de pontes devido ao fluxo de água Balageas et al. (2006), o que pode minar significativamente a estabilidade estrutural de uma ponte. A modelagem da erosão envolve o ajuste das condições de contorno e da rigidez de suporte no modelo de elementos finitos para refletir a perda de suporte.

Figura 31 – Geometria do veículo 2D adotado nas simulações



Fonte: CANTERO, 2024



Fonte: Scour Foundation (2009)

A redução da rigidez da fundação representa a redução do suporte do solo pela diminuição da rigidez dos elementos da fundação. As condições de contorno foram alteradas para simular o efeito do suporte reduzido nas áreas erodidas. Para fins de simulação nesta investigação, K_f é a matriz de rigidez da fundação; na presença de erosão, a matriz de rigidez efetiva K_f^{eff} pode ser expressa conforme a 48.

$$K_f^{eff} = \beta K_f \quad (48)$$

Onde β é um fator de redução ($0 \leq \beta \leq 1$) representando a severidade da erosão. Um valor de $\beta = 0$ implica perda completa de suporte, enquanto $\beta = 1$ implica nenhuma erosão. Neste estudo, dois casos foram avaliados para entender o impacto de diferentes níveis de integridade estrutural. Danos leves são representados com $\beta = 0.95$, indicando uma leve redução no suporte estrutural, enquanto danos mais significativos com $\beta = 0.90$ refletem uma diminuição mais substancial no suporte.

A referência para os valores adotados na rigidez do apoio central foi adotada conforme a descrição de Fitzgerald et al. (2019) para uma fundação de concreto.

4 METODOLOGIA PARA O EMPREGO DO APRENDIZADO NÃO SUPERVISIONADO

Este capítulo detalha a o treinamento de três configurações distintas de *autoencoders* para a reconstrução de sinais de aceleração advindos da simulação computacional entre um veículo e uma estrutura, dispostos com forma 44×44 ou 1×1936 .

Critério de seleção de modelo

O processo de seleção de modelo para o autoencoder convolucional profundo é fundamentado no princípio de minimização da perda de validação. A otimização Bayesiana é empregada para explorar eficientemente este espaço multidimensional, utilizando um processo Gaussiano com função de aquisição baseada em Expected Improvement (EI) implementado com a biblioteca Keras Tuner 1.4.7.

A função de perda de validação adotada foi o erro médio absoluto (MAE). O processo incorpora parada antecipada com paciência de 15 épocas, mitigando assim o overfitting, também com a utilização de um conjunto de validação independente, permitindo uma aproximação não-enviesada do erro de generalização.

Foram feitas 20 rodadas para a escolha dos hiperparâmetros do modelo, incluindo a variação entre agendadores de taxa de aprendizado, otimizadores, tamanho dos filtros de convolução e taxas de dropout, porém o detalhamento da escolha dos hiperparâmetros não entra no escopo deste trabalho.

Tabela 8 – Arquitetura proposta do Autoencoder 1D

Camada (tipo)	Saída	Ativação
Dense	64	ReLU
Dense	32	ReLU
Dense	16	ReLU
Bottleneck	16	-
Dense	16	ReLU
Dense	64	ReLU
Dense	5830	Sigmoid

Estabelecida a topologia dos modelos, a rotina de treinamento foi implementada utilizando Python 3.10.0 e TensorFlow 2.18, executada no sistema operacional MacOS Sequoia 15.1. com chip M2 Pro e 16gb de RAM. O treinamento durou 15 minutos para o autoencoder convolucional 2D e 5 e 4 minutos minutos para os modelo convolucional 1D e autoencoder 1D, respectivamente, utilizando 8 threads.

O pré-processamento dos dados inicia no carregamento dos sinais, aplicando ruído operacional de 5% e redimensionando as medidas de aceleração para o formato que se alinhe com as dimensões de entrada esperadas pelo modelo (matriz 44x44x1 ou vetor 1X1936), procedimento realizado com Matlab e a biblioteca Numpy 2.0.2. Os dados foram dividido em conjuntos de treinamento e validação usando uma proporção 80-20 para facilitar a avaliação do modelo em dados não vistos.

600 respostas de passagens em pontes sem dano (baseline) comporam a base de treinamento do modelo, e posteriormente, foram utilizadas 20 amostras de 30 passagens não vistas pelo modelo na etapa de treinamento para cada cenário (ponte sem dano, 5% e 10% de redução na rigidez do apoio central) no cálculo os índices de dano.

Construiu-se o modelo com a definição de funções personalizadas em Python com a biblioteca TensorFlow que definem sua ar-

Tabela 9 – Arquitetura proposta do Autoencoder Conv1D

Camada (tipo)	Saída	Kernel	Ativação
Entrada	(1936, 1)	-	-
Conv1D	(968, 32)	3	LeakyReLU
Normalização em Lote	(968, 32)	-	-
Dropout	(968, 32)	-	-
Conv1D	(484, 64)	3	LeakyReLU
Normalização em Lote	(484, 64)	-	-
Dropout	(484, 64)	-	-
Conv1D	(242, 128)	3	LeakyReLU
Normalização em Lote	(242, 128)	-	-
Conv1D Transpose	(484, 128)	3	LeakyReLU
Normalização em Lote	(484, 128)	-	-
Dropout	(484, 128)	-	-
Conv1D Transpose	(968, 64)	3	LeakyReLU
Normalização em Lote	(968, 64)	-	-
Dropout	(968, 64)	-	-
Conv1D Transpose	(1936, 32)	3	LeakyReLU
Normalização em Lote	(1936, 32)	-	-
Saída (Conv1D)	(1936, 1)	3	Linear

quitetura e parâmetros de compilação, incluindo o otimizador Adam com recorte de gradiente e a função de perda de erro médio absoluto (MAE) para um treinamento efetivo, similar ao procedimento adotado por Cantero (2024) e Fernandes e Lopez (2023).

Um agendador personalizado de taxa de aprendizagem é implementado para diminuir progressivamente a taxa de aprendizagem após vinte épocas, melhorando a convergência do modelo.

O processo de treinamento incorporou callbacks para parada antecipada para prevenir overfitting, checkpointing do modelo para salvar o modelo com melhor desempenho, e TensorBoard para monitoramento em tempo real das métricas de treinamento.

Após o treinamento, o desempenho da reconstrução é avaliado

comparando os sinais originais e reconstruídos através de gráficos, fornecendo uma avaliação qualitativa da capacidade do autoencoder de capturar e replicar os padrões subjacentes dos dados.

Em seguida, na etapa de análise dos dados, é aplicada a metodologia para monitoramento de saúde estrutural, utilizando o autoencoder convolucional.

Tal etapa consiste no carregamento do melhor autoencoder e 3 novos conjuntos de dados ainda não vistos pelo modelo, contendo sinais de estruturas saudáveis e estruturas com danos induzidos em diferentes níveis (5% e 10%) conforme a equação 48. O autoencoder reconstrói sinais de entrada, e os erros de reconstrução são quantificados usando Erros Médios Absolutos (MAEs).

É ajustada uma distribuição log-normal nos valores de erro de reconstrução da base de sinais saudáveis utilizadas no treinamento, estabelecendo uma referência para o comportamento operacional normal.

Subconjuntos aleatórios de MAEs são amostrados para cada um dos três cenários para contabilizar a variabilidade e analisar parâmetros individuais de distribuição, através do cálculo de índices de dano, obtidos da divergência de Kullback-Leibler (KL) (Erven e Harremoës, 2012) entre a distribuição de MAEs de amostras saudáveis e as distribuições obtidas da reconstrução dos novos dados.

Estes índices de dano cumprem a função de medidas quantitativas de desvio do estado saudável, indicando a presença e severidade do dano estrutural.

A análise avança para a avaliação estatística através de agrupamento (KMeans), classificando as condições baseadas nos índices de dano, com desempenho avaliado via curvas ROC (Receiver Operating Characteristic), para avaliar a capacidade diagnóstica do modelo em distinguir entre estados saudáveis e danificados.

A metodologia propõe que sejam gerados gráficos de dispersão e boxplot, para permitir a liberdade dos agentes de inspeção para decidir os limites tolerados para a calibração de sensibilidade (sensitivity) e chamamento (recall).

4.1 DETECÇÃO DE ANOMALIAS

A definição de limiares para detecção de anomalias em sistemas de SHM requer uma análise minuciosa da relação entre índices de dano e a severidade real do dano estrutural. Güemes et al., 2020 enfatizam que a determinação desses limiares deve considerar a Probabilidade de Detecção (POD), um conceito que emergiu em 1969 através da NASA Defense, 2009, buscando quantificar a confiabilidade dos métodos não-destrutivos de avaliação.

O processo envolve a compreensão da correlação entre índices de dano e extensão do dano através de análises experimentais e simulações numéricas, incluindo modelos de elementos finitos (FEM), para prever o comportamento do índice de dano em diferentes cenários.

O desenvolvimento do model-assisted probability of detection (MAPOD) reduziu a necessidade de testes experimentais extensivos, permitindo a modelagem da resposta à inspeção do material danificado.

A análise da capacidade de detecção de danos em sistemas SHM pode ser quantificada através das métricas de desempenho de classificação binária, conforme explicado por Fawcett, 2006 em seu trabalho "An Introduction to ROC Analysis".

As taxas de Verdadeiros Positivos (TPR) e Falsos Positivos (FPR) são métricas que avaliam a eficácia do sistema de detecção. De acordo com Farrar e Worden, 2012 em "Structural Health Monitoring: A Machine Learning Perspective", a TPR, também conhecida como

sensibilidade, representa a proporção de casos de dano corretamente identificados, enquanto a FPR indica a frequência com que o sistema erroneamente classifica estruturas saudáveis como danificadas.

Curvas ROC (Receiver Operating Characteristic) são ferramentas gráficas que exibem a proporção entre TPR e FPR para diferentes limiares de classificação, originalmente desenvolvidas durante a Segunda Guerra Mundial para análise de sinais de radar Zweig e G. Campbell (1993).

Definições mais clássicas como a de Metz (1978) em "Basic Principles of ROC Analysis" explicam a curva ROC como a visualização de TPR versus FPR para cada valor possível do limiar de decisão, fornecendo uma representação visual abrangente do desempenho de um classificador. A área sob a curva ROC (Area Under the Receiver Operating Characteristic Curve) é uma métrica utilizada para quantificar o desempenho global do sistema de detecção, onde um valor de $AUC = 1$ indica classificação perfeita, enquanto $AUC = 0.5$ caracteriza um desempenho aleatório Bradley (1997)

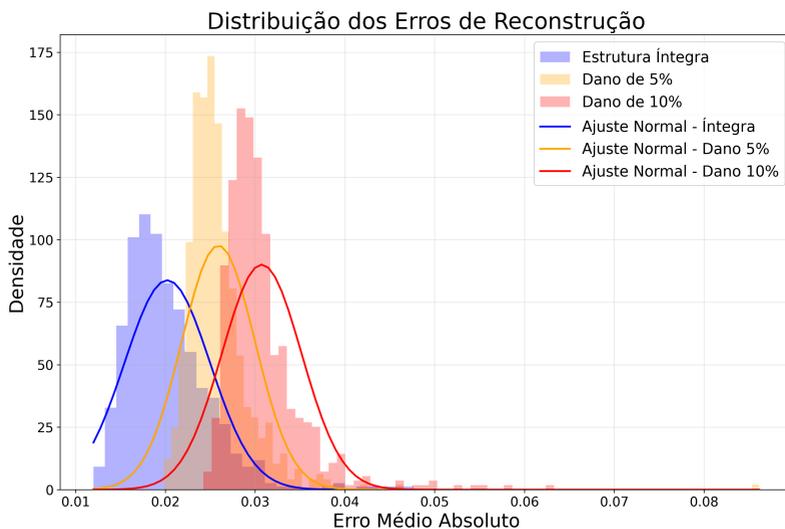
O presente trabalho propõe uma análise cujo objetivo é estabelecer se há uma anomalia na estrutura, tal distinção é um atributo para a tomada de decisão para a priorização de inspeções rotineiras. Conforme Mitre (2005) diversos são os fatores que podem motivar uma inspeção, e caso não haja um específico, realiza-se periodicamente ao menos uma inspeção rotineira (expedita) - doravante, uma análise estatística a respeito de quais estruturas apresentaram um comportamento anômalo contribui para a etapa inicial da identificação da necessidade de realizar uma inspeção.

Quando munido da informação de quais são os ativos cujos comportamentos mais divergem do padrão, é possível otimizar as etapas de planejamento discutidas no primeiro capítulo deste trabalho.

Trabalhos seminais na pesquisa sobre inteligência artificial esta-

belecem uma relação direta entre as capacidades humanas em determinada tarefa, como Goldberg e Holland (1988) define que a aprendizagem de máquina precisa se basear em fenômenos e metáforas naturais para cumprir seu propósito. Por conseguinte, grande parte das atividades de classificação e detecção de anomalias podem ser realizadas por especialistas - ademais, vê-se pela 32 certa distinção entre as distribuições de populações de erros médios absolutos de reconstruções com diversos graus de dano induzido em forma de histograma.

Figura 32 – População de erros de reconstruções de sinais calculados utilizando o MAE CONV2D



Conceitos estatísticos, conforme Xu e Garcia (2008) observa à luz da intuição no repertório comportamental de crianças de apenas oito meses de idade, estão intrinsecamente ligados à percepção humana da realidade. Todavia, em problemas com vastos espaços de busca, a capacidade humana de explorar todas as possibilidades é

limitada, principalmente no processamento de dados em larga escala, na detecção de padrões sutis e na eliminação de vieses.

Quando o volume de dados é massivo, a análise humana se torna impraticável. Métodos estatísticos e algoritmos de aprendizado de máquina, capazes de processar grandes conjuntos de dados, são indispensáveis para extrair padrões significativos.

Contudo, Xu e Garcia (2008) aponta que a expertise humana é suscetível a vieses cognitivos, que podem distorcer a análise e a tomada de decisão: especialistas diferentes chegariam a diferentes conclusões ao classificar as amostras a partir da 32 - seja por uma diferença no limite de tolerância de falsos negativos, ou por mera falta de qualificação. Métodos estatísticos, quando aplicados corretamente, oferecem uma abordagem mais objetiva, minimizando a influência de vieses subjetivos.

4.2 CÁLCULO DO INDICADOR DE DANO

Para calcular um indicador de dano (DI), os valores de MAE são agrupados em amostras, cada uma representando um conjunto de passagens de trem, assume-se que a distribuição dos MAEs para cada amostra segue uma distribuição log-normal, uma vez que, por definição, o erro médio absoluto (MAE) nunca assume valores negativos. Ajusta-se a distribuição para os dados de MAE de cada amostra, incluindo o cenário de referência e os cenários com danos.

Divergência de Kullback-Leibler (KL) é uma medida que quantifica a diferença entre duas distribuições de probabilidade, no caso específico de duas distribuições log-normais, ela fornece uma medida assimétrica da distância entre elas (Erven e Harremoës, 2012). Para duas distribuições log-normais P e Q, esta quantidade de divergência

de informação pode ser calculada pela equação (49) .

$$D_{KL}(P||Q) = \sum_{x \in \mathcal{X}} P(x) \log \left(\frac{P(x)}{Q(x)} \right) \quad (49)$$

A soma é realizada sobre todo o espaço amostral X , onde x representa os valores possíveis no espaço de amostras X . A metodologia adotada por Fernandes e Lopez, 2023, Cantero, 2024 e por este trabalho, propõe que a DKL, apresentada na equação 49, seja calculada entre a distribuição log-normal dos MAEs do cenário de referência (p_0) e a distribuição log-normal dos MAEs de uma amostra de dados de um cenário desconhecido (q_1), e posteriormente utilizada para o cálculo de um índice de dano DI.

$$DI = \ln[D_{KL}(p_0||q_1) + e] - 1 \quad (50)$$

A aplicação da função logarítmica natural (\ln) e a subtração de 1 na equação 50 transformam a divergência em uma relação linear com o nível de dano, possibilitando também o acompanhamento da progressão dos danos ao longo do tempo. Essa linearidade diretamente proporcional será abordada no capítulo seguinte com a apresentação dos resultados e no capítulo final durante as sugestões para trabalhos futuros.

Tabela 10 – Arquitetura proposta do Autoencoder Conv2D

Camada (tipo)	Saída	Kernel	Ativação
Entrada	(44, 44, 1)	-	-
Conv2D	(44, 44, 64)	(3, 3)	ReLU
Normalização em Lote	(44, 44, 64)	-	-
Dropout (0.3)	(44, 44, 64)	-	-
Conv2D	(44, 44, 64)	(3, 3)	ReLU
Normalização em Lote	(44, 44, 64)	-	-
MaxPooling2D	(22, 22, 64)	(2, 2)	-
Conv2D	(22, 22, 128)	(3, 3)	ReLU
Normalização em Lote	(22, 22, 128)	-	-
Dropout (0.3)	(22, 22, 128)	-	-
Conv2D	(22, 22, 128)	(3, 3)	ReLU
Normalização em Lote	(22, 22, 128)	-	-
MaxPooling2D	(11, 11, 128)	(2, 2)	-
Conv2D	(11, 11, 256)	(3, 3)	ReLU
Normalização em Lote	(11, 11, 256)	-	-
Dropout (0.3)	(11, 11, 256)	-	-
Conv2D	(11, 11, 256)	(3, 3)	ReLU
Normalização em Lote	(11, 11, 256)	-	-
MaxPooling2D	(6, 6, 256)	(2, 2)	-
Dense	(128)	-	ReLU
Conv2D Transpose	(11, 11, 256)	(3, 3)	ReLU
Normalização em Lote	(11, 11, 256)	-	-
UpSampling2D	(22, 22, 256)	(2, 2)	-
Conv2D Transpose	(22, 22, 128)	(3, 3)	ReLU
Normalização em Lote	(22, 22, 128)	-	-
UpSampling2D	(44, 44, 128)	(2, 2)	-
Conv2D Transpose	(44, 44, 64)	(3, 3)	ReLU
Normalização em Lote	(44, 44, 64)	-	-
Saída (Conv2D)	(44, 44, 1)	(3, 3)	Sigmoid

5 APRESENTAÇÃO DOS RESULTADOS

Nesta seção, são apresentados os resultados dos índices de dano (DI) para cada caso de estrutura analisado. Esta metodologia propõe a representação dos DIs por meio de gráficos boxplots, permitindo que agentes de inspeção tomem decisões embasadas em estatísticas como média, desvio padrão e análise de outliers, assim como a classificação não supervisionada embasada nos resultados do algoritmo de k-means, para um agrupamento dos casos baseado na correlação linear do índice de dano calculado e o dano induzido na simulação numérica.

O autoencoder unidimensional foi escolhido como modelo base-line para comparação, ele é composto por uma arquitetura de camadas densas projetada para processar vetores unidimensionais de entrada, o mesmo princípio por trás do autoencoder convolucional.

Durante a etapa de **codificação**, a entrada é reduzida progressivamente por meio de camadas densas totalmente conectadas, que aplicam funções de ativação ReLU. Essa redução é realizada em três estágios, diminuindo as dimensões para valores intermediários (128, 64 e 32 neurônios, respectivamente), até atingir uma representação comprimida no espaço latente.

Iniciada a etapa de **decodificação**, a representação latente é expandida gradualmente pelas camadas densas até recuperar o formato original da entrada, com a última camada utilizando a função de ativação.

5.1 RESULTADOS DOS ÍNDICES DE DANO

Os índices de danos calculados através da comparação de 20 amostras com distribuições de erros de reconstrução de 30 passagens de veículos, o resultado das flutuações está expresso em tabelas nesta seção.

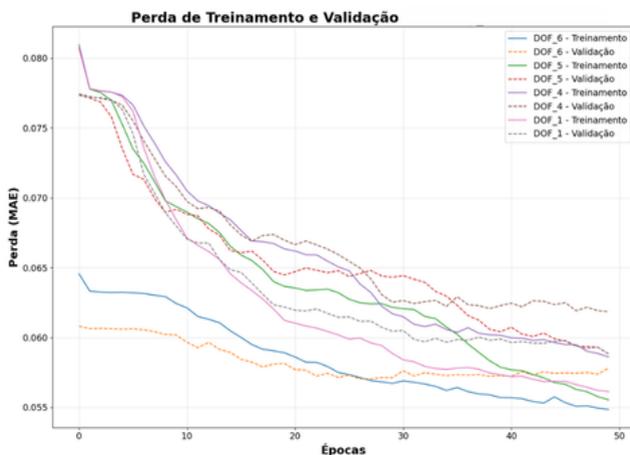


Figura 33 – Treinamento do autoencoder unidimensional

Tabela 11 – Flutuação do modelo CONV1D do índice de dano (DOF 6 - eixo traseiro)

Condição	μ	σ	Mín.	Máx.	Q1	\tilde{x}	Q3	IQR
10% Dano	0.50	0.23	0.06	0.97	0.36	0.43	0.63	0.26
5% Dano	0.64	0.21	0.23	1.00	0.49	0.64	0.78	0.29
Saudável	0.44	0.23	0.00	0.93	0.32	0.39	0.56	0.23

Nota-se que a média e o desvio padrão dos DIs aumentam com o nível de dano na estrutura, indicando que o DI é sensível às mudanças nas condições estruturais e pode ser utilizado como um indicador para detecção de danos. Os melhores resultados foram obtidos para o grau de liberdade DOF5.

Os resultados podem ser visualizados também em forma de boxplot.

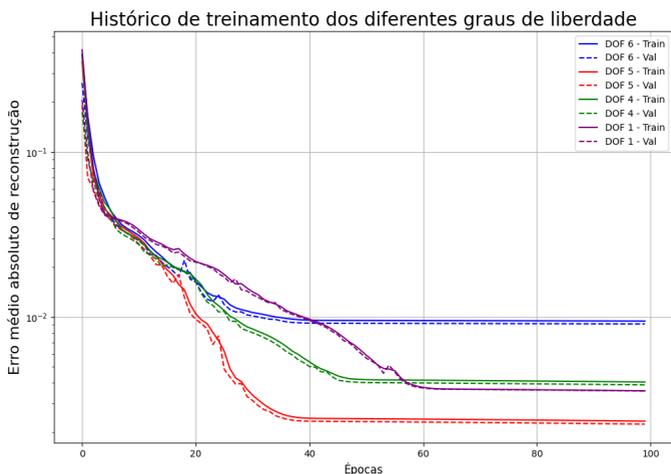


Figura 34 – Treinamento do autoencoder convolucional 1D

Tabela 12 – Flutuação do modelo CONV2D do índice de dano (DOF 6 - eixo traseiro)

Condição	μ	σ	Mín.	Máx.	Q1	\tilde{x}	Q3	IQR
Dano 10%	0.94	0.59	0.00	1.00	0.55	0.95	0.78	1.00
Dano 5%	0.85	0.59	0.00	1.00	0.46	0.85	0.61	0.70
Saudável	0.53	0.43	0.00	1.00	0.43	0.53	0.62	0.62

5.1.1 Classificação não supervisionada com K-Means

Para complementar a análise, a classificação não supervisionada utilizando o algoritmo K-Means foi aplicada, com o propósito de agrupar os dados dos DIs em clusters correspondentes às diferentes condições estruturais, sem utilizar informações prévias sobre os rótulos das amostras.

A tabela 17 contém as estatísticas descritivas da classificação

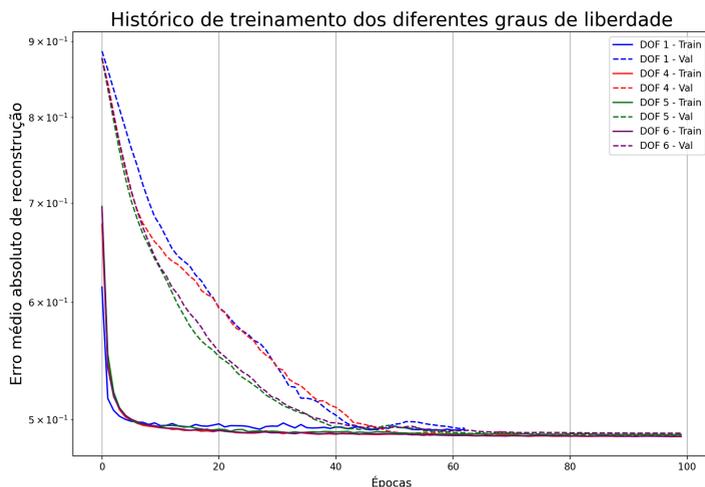


Figura 35 – Treinamento do autoencoder convolucional 2D

Tabela 13 – Flutuação do modelo CONV1D do índice de dano (DOF 5 - truque traseiro do eixo frontal)

Condição	μ	σ	Mín.	Máx.	Q1	\tilde{x}	Q3	IQR
10% Dano	0.62	0.18	0.37	1.0	0.48	0.58	0.70	0.21
5% Dano	0.58	0.18	0.25	0.98	0.48	0.60	0.69	0.20
Saudável	0.38	0.16	0.00	0.79	0.30	0.37	0.46	0.15

realizada com agrupamento k-means.

O algoritmo K-Means foi configurado para três clusters, correspondendo às três condições estruturais: saudável, dano de 5% e dano de 10%. Os resultados da classificação são apresentados em curvas ROC, fundamentados no resultado do algoritmo K-Means.

Tabela 14 – Flutuação do modelo CONV2D do índice de dano (DOF 5 - truque traseiro do eixo frontal)

Condição	μ	σ	Mín.	Máx.	Q1	\tilde{x}	Q3	IQR
10% Dano	0.62	0.22	0.37	1.00	0.49	0.8	0.75	0.21
5% Dano	0.53	0.18	0.25	0.88	0.48	0.60	0.69	0.20
Saudável	0.38	0.16	0.09	0.51	0.30	0.37	0.46	0.15

Tabela 15 – Flutuação CONV2D no cálculo do índice de dano (DOF 1 - cabine)

Condição	μ	σ	Mín.	Máx.	Q1	Med.	Q3	IQR
Dano 10%	0.74	0.41	0.17	1.00	0.55	0.74	0.81	0.36
Dano 5%	0.68	0.43	0.14	0.95	0.50	0.65	0.79	0.47
Saudável	0.66	0.43	0.07	0.92	0.49	0.59	0.75	0.45

Tabela 16 – Flutuação CONV1D no cálculo do índice de dano (DOF 1 - cabine)

Condição	μ	σ	Mín.	Máx.	Q1	Med.	Q3	IQR
10% Dano	0.50	0.276	0.00	0.96	0.26	0.51	0.66	0.40
5% Dano	0.52	0.19	0.16	0.88	0.38	0.52	0.68	0.30
Saudável	0.54	0.24	0.09	1.00	0.32	0.57	0.74	0.41

5.1.2 Curvas ROC

Curvas ROC permitem analisar a capacidade do modelo em distinguir entre as classes (condições estruturais) ao variar o limiar de decisão entre o diagnóstico de estruturas saudáveis e com dano de 5%, e entre estruturas saudáveis e com dano de 10%, conforme apresentado na figura 36.

As áreas sob as curvas (AUC) para as comparações foram calculadas, resultando em valores próximos de 1, o que indica um alto desempenho na discriminação entre as classes. Especificamente, o AUC para a comparação entre saudável e dano de 10% foi superior

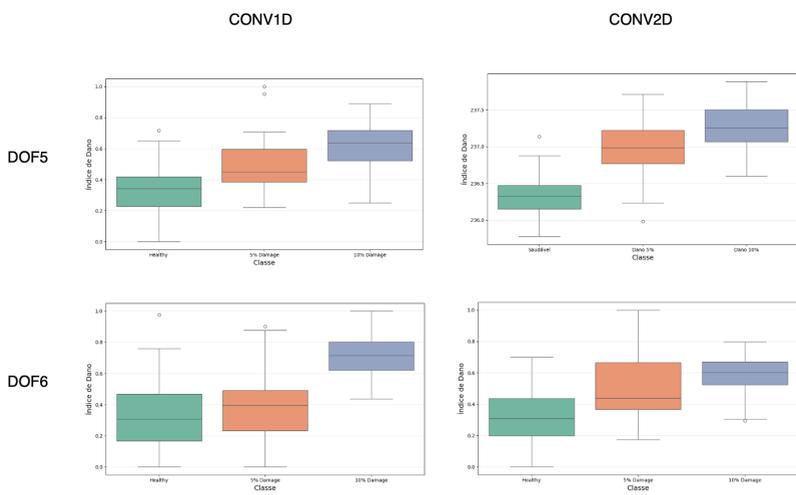
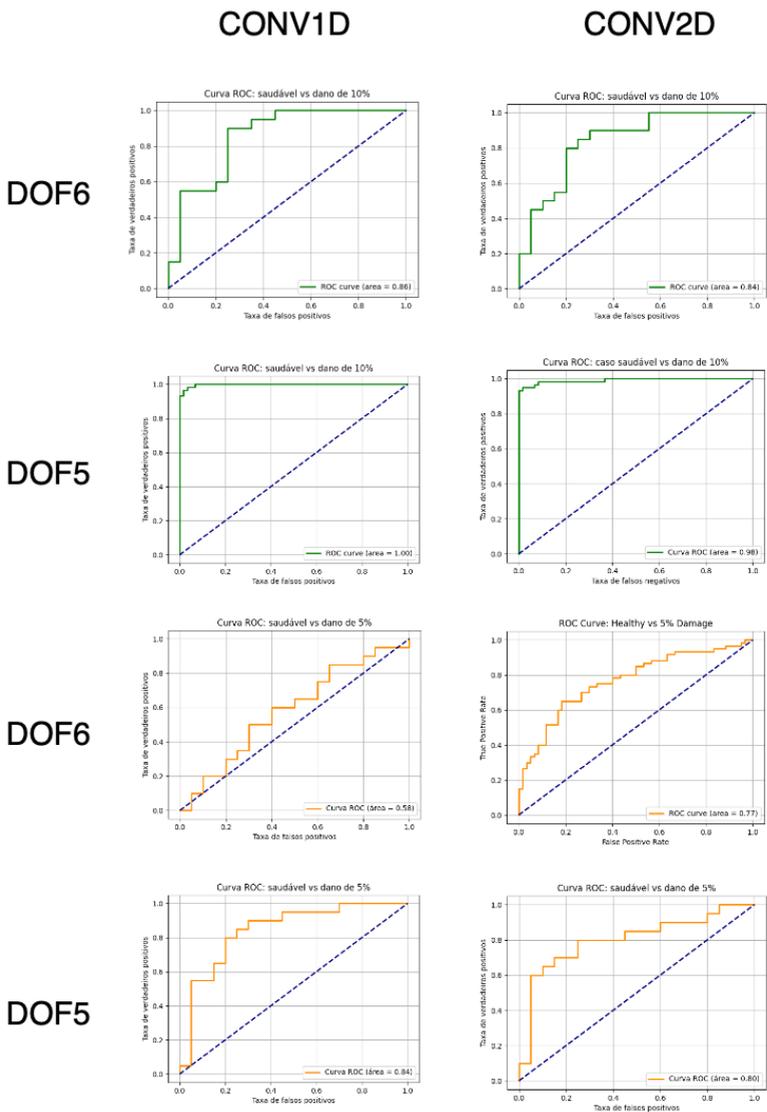


Tabela 17 – Resumo dos resultados de classificação com k-means

Modelo	DOF	Acurácia	Precisão	Revocação	F1-Score
CONV1D	6	0.52	0.39	0.42	0.39
CONV2D	6	0.59	0.60	0.58	0.59
CONV1D	5	0.63	0.54	0.50	0.51
CONV2D	5	0.70	0.70	0.70	0.70
CONV1D	1	0.40	0.39	0.40	0.39
CONV2D	1	0.30	0.29	0.30	0.29

ao da comparação com dano de 5%, refletindo a maior facilidade em detectar danos mais severos.

Figura 36 – Curvas ROC



6 CONCLUSÕES E PROPOSTAS PARA TRABALHOS FUTUROS

6.1 DISCUSSÃO DOS RESULTADOS

Os resultados apresentados confirmam a correlação entre o DI calculado a partir dos sinais de aceleração reconstruídos pelo auto-encoder convolucional. A divergência de Kullback-Leibler, um caso especial da divergência de Rényi, conforme discutido por Erven e Harremoës (2012), se confirma como uma quantidade relevante para extrair a divergência entre a distribuição de erros de reconstrução de sinais oriundos de estruturas anômalas e saudáveis.

O modelo conv2D apresentou a melhor performance em dados inéditos calculando índices de dano que permitem uma distinção entre os cenários de dano, todavia, o histórico de treinamento do melhor modelo conv 2D, visto na figura 35 exibe um custo de validação ligeiramente maior do que o custo de treinamento para as 50 primeiras épocas de treinamento, demonstrando um potencial overfitting.

Apesar de trivial, a aplicação do algoritmo K-Means apresentou bons resultados para a classificação não supervisionada das condições estruturais, distinguindo com uma boa acurácia entre o cenário saudável e o cenário com 10% de dano induzido, auxiliando na identificação de possíveis danos sem a necessidade de rótulos pré-definidos, conforme evidenciado pela figura 36. Entretanto, a acurácia para a detecção de danos menos intensos (5%) foi baixa, conquanto superior a 50% na maioria dos casos.

As curvas ROC confirmam a capacidade do modelo em distinguir entre estruturas saudáveis e danificadas, reforçando a viabilidade do método para aplicações de monitoramento de integridade estrutural em tempo real.

6.2 CONCLUSÕES

Este estudo apresentou uma metodologia baseada em aprendizado não supervisionado e indicadores de danos como prova de conceito para avaliar comportamentos anômalos induzidos por erosão no apoio central em pontes rodoviárias. Os modelos autoencoder convolucional 1D e 2D convergiram quando treinados nos dados dos graus de liberdade 5 e 6, o truque traseiro do eixo frontal, e o eixo traseiro, respectivamente. O autoencoder sem camadas convolucionais não convergiu para nenhum dos graus de liberdade.

A abordagem desenvolvida avaliou a viabilidade da detecção de danos de baixa intensidade utilizando dados de sensores posicionados nos eixo traseiro dos veículos, e a principal contribuição da metodologia proposta é sua independência de conhecimento prévio sobre variabilidade operacional ou rótulos de danos, além da interpretabilidade do modelo para detecção de danos através da detecção de anomalias de sinal, eliminando a necessidade de ferramentas de pré-processamento de dados e extração de features.

A evolução do índice de dano para cada cenário correlacionou com aspectos do comportamento estrutural nos diferentes estados de conservação da estrutura, indicando que os modelos de aprendizado de máquina foram capazes de distinguir as variabilidades operacionais e o ruído de medição da presença de anomalias no comportamento estrutural.

A representação em boxplots exhibe as diferenças entre as condições estruturais, e as estatísticas descritivas corroboram a sensibilidade do DI ao nível de dano. O grau de liberdade 5 mostrou uma distinção mais clara entre os cenários de dano, porém, para todos os casos, a distribuição de DI das amostras com 5% de dano induzido possui valores dentro da faixa de valores da distribuição de DI para as amostras

saudáveis.

Para as amostras com 10% de dano de scour induzido, a mediana do índice de dano foi significativamente superior aos casos saudáveis e com 5% de dano, indicando alterações estruturais perceptíveis. Observaram-se picos no desvio padrão, evidenciando uma variabilidade mais pronunciada na presença de danos mais severos.

6.3 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Recomenda-se o desenvolvimento de técnicas para análises mais avançadas de localização, classificação e quantificação de danos, bem como a validação da metodologia de monitoramento drive-by através de dados de campo.

É notório que este estudo utilizou exclusivamente dados de aceleração simulados numericamente, sendo a validação por meio de dados de campo crucial para garantir que os modelos propostos possam ser efetivamente adotados pelos gestores de infraestrutura rodoviária, considerando os desafios de modelar com precisão cenários da vida real que envolvem complexidades da variabilidade ambiental e operacional.

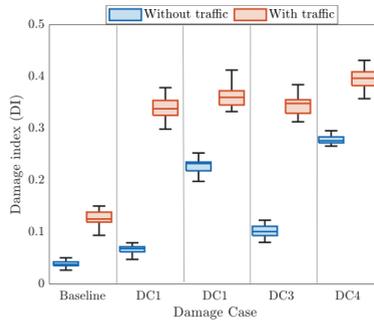
Para trabalhos futuros, sugere-se explorar modelos mais complexos, tridimensionais, que incorporem a interação solo-fundação-pilar e efeitos laterais do veículo, além dos efeitos da temperatura nos modelos de superestrutura e subestrutura. Também sugere-se explorar o impacto que diferentes métodos de integração para a resolução do sistema dinâmico podem ter na coleta de dados simulados computacionalmente através de softwares como o VBI.

Também recomenda-se a utilização de algoritmos de classificação mais elaborados do que o K-Means para aumentar a precisão da detecção de danos mais sutis.

Além disso, é necessário estudo sobre cenários de dano cada

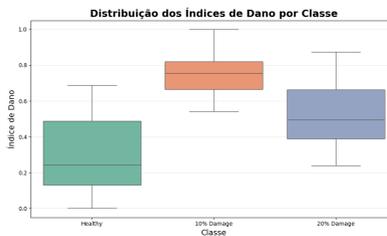
vez mais sutis (menores que 5%), estes casos devem ser incorporados nas análises para avaliar se há correlações não lineares entre as faixas de dano, conforme apresentado por Cantero (2024), foi aferida uma correlação não linear entre danos de 20% e danos de 10%, evidenciado na Figura 18, página 13 sec 6.1 acentuada para cenários sem a influência de tráfego. Esta investigação confirmou a mesma correlação, conforme a 38.

Figura 37 – Correlação não linear do índice de dano calculado para 10% (DC1) e 20% (DC2) de scour para cenários sem a presença de tráfego



Fonte: Apresentado por Cantero (2024)

Figura 38 – Correlação não linear do índice de dano calculado para 10% e 20% de scour (conv1D DOF 5)



Dessa forma, para refinar o processo de classificação da intensidade do dano, se faz necessária a interpretação das divergências para além de relações lineares entre entropias de informação. Sugere-se o estudo de outras quantidades de informação, descritas por Erven e Harremoës (2012), ou então uma revisão das condições assumidas a respeito das distribuições de erros de reconstrução para este problema específico.

BIBLIOGRAFIA

- "Golpayegani, S. e C. Moloney (2019). "A machine learning approach to bridge-damage detection using responses measured on a passing vehicle". Em: *Sensors* 19.18, p. 4035.
- Abdel-Hamid, O., A.-r. Mohamed, H. Jiang, L. Deng, G. Penn e D. Yu (2014). "Convolutional Neural Networks for Speech Recognition". Em: *IEEE/ACM Transactions on Audio, Speech, and Language Processing* 22.10, pp. 1533–1545. DOI: 10.1109/TASLP.2014.2339736.
- Abiodun, O., A. Jantan, A. Omolara, K. Dada, N. Mohamed e H. Arshad (nov. de 2018). "State-of-the-art in artificial neural network applications: A survey". Em: *Heliyon* 4.11, e00938. DOI: 10.1016/j.heliyon.2018.e00938. Disp. em: <https://doi.org/10.1016/j.heliyon.2018.e00938>.
- Adeli, H. (2006). "Signal processing techniques for vibration-based health monitoring of smart structures". Em: *Archives of Computational Methods in Engineering* 23.12047, pp. 43–62.

- American Association of State and Highway Transportation Officials (1998). *Manual of Condition Evaluation of Bridges*. 2nd. AASHTO, p. 148.
- Anaissi, A. (2022). “Multi-objective variational autoencoder: an application for smart infrastructure maintenance”. Em: *Springer* 53.12047, pp. 1–16.
- Balageas, D., C.-P. Fritzen e A. Güemes (2006). *Structural Health Monitoring*. Institut de Mécanique et d’Ingénierie de Bordeaux, French National Centre for Scientific Research; University of Siegen. London, UK: ISTE Ltd. ISBN: 9781905209019. DOI: 10.1002/9780470612071.
- Bank, D., N. Koenigstein e R. Giryes (2020). “Autoencoders”. Em: *ArXiv* abs/2003.05991.
- Bao, Y., Z. Tang, H. Li e Y. Zhang (2019). “Computer vision and deep learning–based data anomaly detection method for structural health monitoring”. Em: *Structural Health Monitoring* 18.2, pp. 401–421.
- Bergstra, J. e Y. Bengio (2011). “Random search for hyperparameter optimization”. Em: *Journal of Machine Learning Research* 13.1, pp. 281–305.

- BÉTON, C. E.-I. D. (1989). *Diagnosis and assessment of concrete structures. State of the art report*. Boletim 192. Lausanne: CEB, p. 120.
- Béton, F. I. du (2000). *Guidance for good bridge design*. Boletim 9. Lausanne: fib.
- Bishop, C. (2006). *Pattern Recognition and Machine Learning*. Berlin, Heidelberg: Springer-Verlag.
- Bishop, C. M. (2006). “Pattern Recognition and Machine Learning”. Em: *Information Science and Statistics*.
- Bradley, A. P. (1997). “The use of the area under the ROC curve in the evaluation of machine learning algorithms”. Em: *Pattern Recognition* 30.7, pp. 1145–1159.
- Campbell, M., A. J. Hoane e F.-h. Hsu (2002). “Deep Blue”. Em: *Artificial Intelligence* 134.1-2. Details the development and success of Deep Blue., pp. 57–83. DOI: 10.1016/S0004-3702(01)00129-1.
- Cantero, D. (2024). “VBI-2D – Road vehicle-bridge interaction simulation tool and verification framework for Matlab”. Em: *SoftwareX* 26, p. 101725. ISSN: 2352-7110. DOI: <https://doi.org/10.1016/j.softx.2024.101725>.

Disp. em: <https://www.sciencedirect.com/science/article/pii/S2352711024000967>.

Cong Ye Sin-Chi Kuok, L. J. B. e C. R. Middleton (2022). “Implementing bridge model updating for operation and maintenance purposes: examination based on UK practitioners’ views”. Em: *Structure and Infrastructure Engineering* 18.12, pp. 1638–1657. DOI: 10.1080/15732479.2021.1914115.

Corbally, R. e A. Malekjafarian (2022). “A data-driven approach for drive-by damage detection in bridges considering the influence of temperature change”. Em: *Engineering Structures* 253, p. 113783.

Defense, D. of (abr. de 2009). *Nondestructive Evaluation System Reliability Assessment*. Rel. técn. MIL-HDBK-1823A. This handbook is for guidance only. Do not cite this document as a requirement. Department of Defense.

DNIT (2004). *Inspeções em pontes e viadutos de concreto armado e protendido: procedimento*. Norma Técnica. Rio de Janeiro: Departamento Nacional de Infraestrutura de Transportes.

- Erven, T. van e P. Harremoës (2012). “Rényi Divergence and Kullback-Leibler Divergence”. Em: *CoRR* abs/1206.2459. arXiv: 1206.2459. Disp. em: <http://arxiv.org/abs/1206.2459>.
- Fallahian, M., F. Khoshnoudian e V. Meruane (2018). “Ensemble classification method for structural damage assessment under varying temperature”. Em: *Structural Health Monitoring* 17.4, pp. 747–762.
- Farrar, C. R. e K. Worden (2012). *Structural Health Monitoring: A Machine Learning Perspective*. A catalogue record for this book is available from the British Library and the Library of Congress. Hoboken, NJ, USA: Wiley. ISBN: 978-1-119-99433-6.
- Fawcett, T. (jun. de 2006). “Introduction to ROC analysis”. Em: *Pattern Recognition Letters* 27, pp. 861–874. DOI: 10.1016/j.patrec.2005.10.010.
- Fédération Internationale du Béton (2000). *Guidance for Good Bridge Design*. Boletim 9. Lausanne: fib.
- Fernandes e R. Lopez (dez. de 2023). “Drive-by damage detection in railway bridges subject to operational variabilities using deep autoencoder”. Em: *XLIV Ibero-Latin*

American Congress on Computational Methods in Engineering (CILAMCE 2023).

Fernandes, T., R. Lopes e D. Ribeiro (2024). “Different sensor placement strategies”. Em: *Department of Civil Engineering, Federal University of Santa Catarina (UFSC), Florianópolis, SC, Brazil*. CONSTRUCT-LESE, School of Engineering, Polytechnic of Porto, Porto, Portugal.

Fitzgerald, C., A. Malekjafarian, B. Bhowmik, L. J. Prendergast, P. Cahill, C.-W. Kim, B. Hazra, V. Pakrashi e E. J. OBrien (2019). “Implementing bridge model updating for operation and maintenance purposes: examination based on UK practitioners’ views”. Em: *Sensors* 19.11. This article belongs to the Special Issue Bridge Damage Detection with Sensing Technology, p. 2572. DOI: 10.3390/s19112572.

Fryba, L. (1972). “Vibration of solids and structures under moving loads,(1972)”. Em: *Academia, Prague*.

Goldberg, D. e J. Holland (1988). “Genetic algorithms and Machine Learning”. Em: *Machine Learning* 3, pp. 95–99. DOI: 10.1007/BF00113892.

- Greene, D., P. Cunningham e R. Mayer (2008). “Unsupervised Learning and Clustering”. Em: *Machine Learning Techniques for Multimedia: Case Studies on Organization and Retrieval*. Ed. por M. Cord e P. Cunningham. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 51–90. DOI: 10.1007/978-3-540-75171-7_3. Disp. em: https://doi.org/10.1007/978-3-540-75171-7_3.
- Güemes, A., A. Fernandez-Lopez, A. R. Pozo e J. Sierra-Pérez (2020). “Structural Health Monitoring for Advanced Composite Structures: A Review”. Em: *Journal of Sensors* 2020, pp. 1–20. DOI: 10.1155/2020/4372161.
- Guyon, I. e A. Elisseeff (2003). “An introduction to variable and feature selection”. Em: *Journal of Machine Learning Research* 3, pp. 1157–1182.
- Hastie, T., R. Tibshirani e J. Friedman (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd. New York: Springer. ISBN: 9780387848570.
- Helene, P. (1993). “Contribuição ao estudo da corrosão em armaduras de concreto armado”. Tese (Livre-Docência). Tese de dout. São Paulo: Escola Politécnica da Universidade de São Paulo, p. 231.

- Hinton, G. E. e T. Sejnowski (set. de 2018). “Unsupervised Learning”. Em: *ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*. Springer. DOI: 10.1007/978-3-319-17885-1_101437.
- Ibracon (2019). *Revista Concreto e Construções*. http://ibracon.org.br/Site_revista/Concreto_Construcoes/pdfs/revista95.pdf. Acesso em: 17 nov. 2024.
- ISO (2016). *Mechanical vibration — Road surface profiles — Reporting of measured data*. 2^a ed. 608:2016. ISO, p. 36.
- James, G., D. Witten, T. Hastie e R. Tibshirani (2013). *Statistical Learning*. Springer.
- Jang, J. et al. (2010). “Smart Structures and Systems”. Em: *Smart Structures and Systems* 6.5-6, pp. 439–459.
- KAISER, H. e V. M. KARBHARI (2004). “Non-destructive testing techniques for FRP rehabilitated concrete. I: a critical review”. Em: *International Journal of Microstructure and Materials Properties* 1.4, pp. 349–384. DOI: 10.1504/IJMPT.2004.004996. Disp. em: <https://doi.org/10.1504/IJMPT.2004.004996>.

- Kamariotis, A. (jan. de 2024). *Monitoring-Supported Value Generation for Managing Structures and Infrastructure Systems*. Available at ResearchGate. DOI: 10.48550/arXiv.2402.00021. Disp. em: <https://www.researchgate.net/publication/377969776>.
- L. Deng, W. W. e Y. Yu (2016). “State-of-the-art review on the causes and mechanisms of bridge collapse”. Em: *Journal of Performance of Constructed Facilities* 30, p. 04015005.
- Landman, R. (2001). *Inspeção de obras-de-arte especiais rodoviárias das regiões sul e sudeste do Brasil*. Relatório técnico. São Paulo: Brücken Engenharia de Inspeção de Estruturas.
- LeCun, Y., Y. Bengio e G. Hinton (2015). “Deep learning”. Em: *Nature* 521.7553. Explores the potential of deep learning as a universal approach to AI., pp. 436–444. DOI: 10.1038/nature14539.
- Lee, H., R. Grosse, R. Ranganath e A. Y. Ng (2009). “Convolutional Deep Belief Networks for Scalable Unsupervised Learning of Hierarchical Representations”. Em: *Computer Science Department, Stanford University*.

- Lei, X., Y. Xia, A. Wang, X. Jian, H. Zhong e L. Sun (2023). “Mutual information based anomaly detection of monitoring data with attention mechanism and residual learning”. Em: *Mechanical Systems and Signal Processing* 182, p. 109607.
- Li, Z., W. Lin e Y. Zhang (2023a). “Drive-by bridge damage detection using mel-frequency cepstral coefficients and support vector machine”. Em: *Structural Health Monitoring*. SAGE Publications Sage UK: London, England.
- (2023b). “Real-time drive-by bridge damage detection using deep auto-encoder”. Em: *Structures* 47, pp. 1167–1181.
- Lin, C. e Y. Yang (2005). “Use of a passing vehicle to scan the fundamental bridge frequencies: An experimental verification”. Em: *Engineering Structures* 27.13, pp. 1865–1878.
- Liu, J., S. Chen, M. Bergés, J. Bielak, J. Garrett, J. Kovačević e H. Noh (2020). “Diagnosis algorithms for indirect structural health monitoring of a bridge model via dimensionality reduction”. Em: *Mechanical Systems and Signal Processing* 136, p. 106454.

- Locke, W., J. Sybrandt, L. Redmond, I. Safro e S. Atamturktur (2020). “Using drive-by health monitoring to detect bridge damage considering environmental and operational effects”. Em: *Journal of Sound and Vibration* 468, p. 115088.
- M. Carnevale, A. C. e T. Peirlinck (2019). “A feasibility study of the drive-by method for damage detection in railway bridges”. Em: *Applied Sciences* 9, p. 160.
- Malekjafarian, A., P. McGetrick e E. Obrien (2015). “A review of indirect bridge monitoring using passing vehicles”. Em: *Shock and Vibration*. DOI: 10.1155/2015/286139.
- Malekjafarian, A., F. Golpayegani, C. Moloney e S. Clarke (2019). “A Machine Learning Approach to Bridge-Damage Detection Using Responses Measured on a Passing Vehicle”. Em: *Sensors* 19.18. ISSN: 1424-8220. DOI: 10.3390/s19184035. Disp. em: <https://www.mdpi.com/1424-8220/19/18/4035>.
- Mao, J., H. Wang e B. Jr (2021). “Toward data anomaly detection for automated structural health monitoring: Exploiting generative adversarial nets and autoencoders”. Em: *Structural Health Monitoring* 20.4, pp. 1609–1626.

- McCorduck, P. (2004). “Machines Who Think: A Personal Inquiry into the History and Prospects of Artificial Intelligence”. Em: Includes details on R1 and its impact on Digital Equipment Corporation., p. 434.
- Metin, C. e D. O. Frost (1989). “Visual connections to the somatosensory system”. Em: *Experimental Brain Research* 77.3. Demonstra a adaptação do córtex somatossensorial para processar informações visuais., pp. 607–620. DOI: 10.1007/BF00249612.
- Metz, C. E. (out. de 1978). “Basic principles of ROC analysis”. English. Em: *Seminars in Nuclear Medicine* 8.4. PubMed ID: 112681, pp. 283–298. ISSN: 0001-2998. DOI: 10.1016/s0001-2998(78)80014-2.
- Minski, L. e R. Lopez (dez. de 2023). “Drive-by Damage Detection In Railway Bridges Using 1d Convolutional Neural Networks”. Em: *XLIV Ibero-Latin American Congress on Computational Methods in Engineering (CILAMCE 2023)*.
- Mitre, M. P. (2005). “Metodologia para inspeção e diagnóstico de pontes e viadutos de concreto.” Em: *Escola Politécnica da Universidade de São Paulo*.

- Mokalled, S., W. Locke, O. Abuodeh, L. Redmond e C. McMahan (2022). “Drive-by health monitoring of highway bridges using Bayesian estimation technique for damage classification”. Em: *Structural Control and Health Monitoring* 29.6, e2944.
- NBR (dez. de 2023). *NBR94521 - Inspeção de pontes, viadutos e passarelas - Procedimento*. Publicado em 12 de dezembro de 2023. Rio de Janeiro.
- Ni, F., J. Zhang e M. Noori (2020). “Deep learning for data anomaly detection and data compression of a long-span suspension bridge”. Em: *Computer-Aided Civil and Infrastructure Engineering* 35.7, pp. 685–700.
- Patlatzoglou, K. (2023). “Deep Learning for Electrophysiological Investigation and Estimation of Anesthetic-Induced Unconsciousness”. Doctor of Philosophy Dissertation. University of Kent.
- Pizarro, A., S. Manfreda e E. Tubaldi (2020). “The Science behind Scour at Bridge Foundations: A Review”. Em: *Water* 12.2, p. 374. DOI: 10.3390/w12020374.
- Prieto, A., B. Prieto, E. M. Ortigosa, E. Ros, F. Pelayo, J. Ortega e I. Rojas (2016). “Neural networks: An overview

- of early research, current frameworks and new challenges”. Em: *Neurocomputing* 214, pp. 242–268. ISSN: 0925-2312. DOI: <https://doi.org/10.1016/j.neucom.2016.06.014>. Disp. em: <https://www.sciencedirect.com/science/article/pii/S0925231216305550>.
- Rashidi, H., N. Tran, E. Vali Betts e L. P. Howell (2019). “Artificial Intelligence and Machine Learning in Pathology: The Present Landscape of Supervised Methods”. Em: *Academic Pathology* 6, p. 237428951987308. DOI: 10.1177/2374289519873088. Disp. em: <https://doi.org/10.1177/2374289519873088>.
- Rich, A. (1875). *Pons. The Roman Bridge*. http://www.ukans.edu/history/index/europe/ancient_rome/E/Roman/Texts/secondary/SMIGRA*/Pons.html. Smith’s Dictionary. Disp. em: http://www.ukans.edu/history/index/europe/ancient_rome/E/Roman/Texts/secondary/SMIGRA*/Pons.html.
- Roe, A. W., S. L. Pallas, Y. H. Kwon e M. Sur (1992). “Visual projections routed to the auditory pathway in ferrets: receptive fields of visual neurons in primary auditory cortex”. Em: *Journal of Neuroscience* 12.9. Evidencia a plasticidade do córtex auditivo ao processar inputs

- visuais., pp. 3651–3664. DOI: 10.1523/JNEUROSCI.12-09-03651.1992.
- Ruder, S. (2017). *An overview of gradient descent optimization algorithms*. arXiv: 1609.04747.
- Russell, S. e P. Norvig (2010). *Artificial Intelligence: A Modern Approach*. 3rd. Discusses R1 and the broader implications of expert systems, as well as Deep Blue's contributions to AI. Upper Saddle River, NJ: Pearson Education, pp. 103–104, 111–112. ISBN: 978-0-13-604259-4.
- Samuel, A. L. (1959). “Some Studies in Machine Learning Using the Game of Checkers”. Em: *IBM Journal of Research and Development* 3.3, pp. 210–229. DOI: 10.1147/rd.33.0210.
- Sarker, I. H. (18 de ago. de 2021). “Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions”. Em: *SN Computer Science* 2.6, p. 420. ISSN: 2661-8907. DOI: 10.1007/s42979-021-00815-1. Disp. em: <https://doi.org/10.1007/s42979-021-00815-1>.

- Sarmadi, H. e A. Karamodin (2020). “A novel anomaly detection method based on adaptive Mahalanobis-squared distance and one-class knn rule for structural health monitoring under environmental effects”. Em: *Mechanical Systems and Signal Processing* 140, p. 106495.
- Sarwar, M. Z. e D. Cantero (2021). “Deep autoencoder architecture for bridge damage assessment using responses from several vehicles”. Em: *Engineering Structures* 246, p. 113064. DOI: 10.1016/j.engstruct.2021.113064. Disp. em: <https://doi.org/10.1016/j.engstruct.2021.113064>.
- Sarwar, M. Z. e D. Cantero (nov. de 2023). “Vehicle Assisted Bridge Damage Assessment Using Probabilistic Deep Learning”. Em: *Measurement* 206, p. 112216. ISSN: 0263-2241.
- SHULL, P. J. (2001). *Nondestructive Evaluation: Theory, Techniques, and Applications*. 1st. Boca Raton: CRC Press, p. 876. ISBN: 9780429213397. DOI: <https://doi.org/10.1201/9780203911068>.
- Snoek, J., H. Larochelle e R. P. Adams (2012). “Practical Bayesian optimization of machine learning algorithms”.

- Em: *Advances in Neural Information Processing Systems*.
Vol. 25. Curran Associates, Inc., pp. 2951–2959.
- Soofi, A. A. e A. Awan (2017). “Classification Techniques in Machine Learning: Applications and Issues”. Em: *Journal of Basic & Applied Sciences* 13. © 2017 Lifescience Global, pp. 459–465. ISSN: 1814-8085.
- Souza, P. V. e R. Lopez (dez. de 2023). “Spatial transformer-based Machine learning architecture for bridge dam-age detection via car-mounted sensors”. Em: *XLIV Ibero-Latin American Congress on Computational Methods in Engineering (CILAMCE 2023)*.
- Sparrow, E. (1980). “Forced Convection Heat Transfer in a Duct Having Spanwise-Periodic Rectangular Protuberances”. Em: *Numerical Heat Transfer* 3, pp. 149–167.
- Spencer Jr., B., J. Park, K. Mechitov, H. Jo e G. Agha (2017). “Next generation wireless smart sensors to sustainable civil infrastructure”. Em: *Procedia Engineering* 171, pp. 5–13. DOI: 10.1016/j.proeng.2017.01.304.
- Srivastava, N., G. Hinton, A. Krizhevsky, I. Sutskever e R. Salakhutdinov (2014). “Dropout: A simple way to pre-

- vent neural networks from overfitting”. Em: *The Journal of Machine Learning Research* 15.1, pp. 1929–1958.
- Svozil, D., V. Kvasnicka e J. Pospichal (1997a). “Introduction to multi-layer feed-forward neural networks”. Em: *Chemometrics and Intelligent Laboratory Systems* 39.1, pp. 43–62.
- Svozil, D., V. Kvasnicka e J. Pospichal (1997b). “Introduction to multi-layer feed-forward neural networks”. Em: *Chemometrics and Intelligent Laboratory Systems* 39.1, pp. 43–62. ISSN: 0169-7439. DOI: [https://doi.org/10.1016/S0169-7439\(97\)00061-0](https://doi.org/10.1016/S0169-7439(97)00061-0). Disp. em: <https://www.sciencedirect.com/science/article/pii/S0169743997000610>.
- Vaddi, R. e P. Manoharan (2020). “Hyperspectral image classification using CNN with spectral and spatial features integration”. Em: *Infrared Physics & Technology* 107, p. 103296. ISSN: 1350-4495. DOI: <https://doi.org/10.1016/j.infrared.2020.103296>. Disp. em: <https://www.sciencedirect.com/science/article/pii/S1350449520300876>.

- Valle, M. E. (2024). *MS571/MT571 - Aprendizado de Máquinas: Aula 08 – Problemas Multiclasse e Regressão Softmax*. Lecture Notes.
- Wang, C., X. Yu e F. Liang (jun. de 2017). “A review of bridge scour: mechanism, estimation, monitoring and countermeasures”. Em: *Natural Hazards* 87.3, pp. 1881–1906. ISSN: 1573-0840. DOI: 10.1007/s11069-017-2842-2. Disp. em: <https://doi.org/10.1007/s11069-017-2842-2>.
- Xu, F. e V. Garcia (2008). “Intuitive statistics by 8-month-old infants”. Em: *Proceedings of the National Academy of Sciences*.
- Yang, Y.-B., J. Yau, Z. Yao e Y. Wu (2004). *Vehicle-bridge interaction dynamics: with applications to high-speed railways*. World Scientific.
- Yin, X., W. Chen, X. Wu e H. Yue (2017). “Fine-tuning and visualization of convolutional neural networks”. Em: *2017 12th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, pp. 1310–1315. DOI: 10.1109/ICIEA.2017.8283041.

- Ying, X. (fev. de 2019). “An Overview of Overfitting and its Solutions”. Em: *Journal of Physics: Conference Series* 1168.2, p. 022022. DOI: 10.1088/1742-6596/1168/2/022022.
- Zavala-Mondragón, L. A., P. H. N. de With e F. van der Sommen (2023). *A signal processing interpretation of noise-reduction convolutional neural networks*. arXiv: 2307.13425.
- ZHANG, H., J. LIN, J. HUA, F. GAO e T. TONG (2022). “Data anomaly detection for bridge SHM based on CNN combined with statistic features”. Em: *Journal of Non-destructive Evaluation* 41.1, pp. 1–13.
- Zhao, X., L. Wang, Y. Zhang, X. Han, M. Deveci e M. Parmar (mar. de 2024). “A review of convolutional neural networks in computer vision”. Em: *Artificial Intelligence Review* 57.4, p. 99. ISSN: 1573-7462. DOI: 10.1007/s10462-024-10721-6. Disp. em: <https://doi.org/10.1007/s10462-024-10721-6>.
- Zweig, M. H. e G. Campbell (1993). “Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine”. Em: *Clinical Chemistry* 39.4, pp. 561–577.