



UNIVERSIDADE FEDERAL DE GOIÁS – REGIONAL CATALÃO  
UNIDADE ACADÊMICA ESPECIAL DE MATEMÁTICA E TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM E OTIMIZAÇÃO



**Stanley Washington Ferreira de Rezende**

TÉCNICAS DE APRENDIZADO PROFUNDO APLICADAS AO  
MONITORAMENTO DE INTEGRIDADE ESTRUTURAL POR  
IMPEDÂNCIA ELETROMECHANICA

**DISSERTAÇÃO DE MESTRADO**

CATALÃO – GO, 2021



UNIVERSIDADE FEDERAL DE GOIÁS  
UNIDADE ACADÊMICA ESPECIAL DE MATEMÁTICA E TECNOLOGIA

## TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

### 1. Identificação do material bibliográfico

Dissertação     Tese

### 2. Nome completo do autor

Stanley Washington Ferreira de Rezende

### 3. Título do trabalho

Técnicas de Aprendizado Profundo Aplicadas ao Monitoramento de Integridade Estrutural por Impedância Eletromecânica

### 4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento  SIM     NÃO<sup>1</sup>

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

- a) consulta ao(a) autor(a) e ao(a) orientador(a);
  - b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.
- O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

**Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.**



Documento assinado eletronicamente por **Jose Dos Reis Vieira De Moura Junior, Orientador**, em 21/07/2021, às 16:39, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **STANLEY WASHINGTON FERREIRA DE REZENDE, Discente**, em 21/07/2021, às 16:41, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **2225341** e o código CRC **1ADFD057**.

STANLEY WASHINGTON FERREIRA DE REZENDE

TÉCNICAS DE APRENDIZADO PROFUNDO APLICADAS AO  
MONITORAMENTO DE INTEGRIDADE ESTRUTURAL POR  
IMPEDÂNCIA ELETROMECAÂNICA

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem e Otimização, da Unidade Acadêmica de Matemática e Tecnologia da Universidade Federal de Goiás (UFG), como requisito para obtenção do título de Mestre em Modelagem e Otimização.  
Àrea de Concentração: Modelagem e Otimização.

Orientador:  
José dos Reis Vieira de Moura Júnior

CATALÃO – GO

2021

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Rezende, Stanley Washington Ferreira de  
Técnicas de Aprendizado Profundo Aplicadas ao Monitoramento de Integridade Estrutural por Impedância Eletromecânica [manuscrito] / Stanley Washington Ferreira de Rezende. - 2021.  
CXLIII, 143 f.

Orientador: Prof. Dr. José dos Reis Vieira de Moura Júnior.  
Dissertação (Mestrado) - Universidade Federal de Goiás, Unidade Acadêmica Especial de Matemática e Tecnologia, Catalão, Programa de Pós-Graduação em Modelagem e Otimização, Catalão, 2021.

Inclui siglas, abreviaturas, gráfico, tabelas, algoritmos, lista de figuras, lista de tabelas.

1. Monitoramento de Integridade Estrutural. 2. Impedância Eletromecânica. 3. Aprendizado Profundo. 4. Redes Neurais Convolucionais. 5. Long Short-TermMemory. I. Moura Júnior, José dos Reis Vieira de, orient. II. Título.

CDU 621



UNIVERSIDADE FEDERAL DE GOIÁS  
UNIDADE ACADÊMICA ESPECIAL DE MATEMÁTICA E TECNOLOGIA  
**ATA DE DEFESA DE DISSERTAÇÃO**

Ata nº **09** da sessão de Defesa de Dissertação de **Stanley Washington Ferreira de Rezende**, que confere o título de Mestre(a) em **Modelagem e Otimização**, na área de concentração em **Modelagem e Otimização**.

Ao/s **doze de julho**, a partir da(s) **9h00min**, por Webconferência, via sistema Sala google meeting, reuniram-se os componentes da banca examinadora, professores(as) Dr. José dos Reis Vieira de Moura Júnior (orientador) (PPGMO - "RC/UFG - UFCAT em transição"), Dr. Marcos Napoleão Rabelo (PPGMO - "RC/UFG - UFCAT em transição"), Dr. William Júnio de Lima (INFIS/UFU) para, em sessão pública, procederem à avaliação da Dissertação intitulada "Técnicas de Aprendizado Profundo Aplicadas ao Monitoramento de Integridade Estrutural por Impedância Eletromecânica", autoria de Stanley Washington Ferreira de Rezende, discente do Programa de Pós-Graduação em Modelagem e Otimização - PPGMO, da "RC/UFG - UFCAT em transição". A sessão foi aberta pelo presidente, que fez a apresentação formal dos membros da banca. Em seguida, a palavra foi concedida ao discente que, em cinquenta minutos procedeu à apresentação. Terminada a apresentação, cada membro da banca arguiu o examinando. Terminada a fase de arguição, procedeu-se à avaliação da Dissertação, que foi considerada: (X) Aprovado(a) ou ( ) Reprovado(a). Cumpridas as formalidades de pauta, a presidência da mesa encerrou a sessão e, para constar, lavrou-se a presente ata que, depois de lida e aprovada, segue assinada pelos membros da banca examinadora e pelo discente. Obs.: "*Banca Examinadora de Qualificação/Defesa Pública de Dissertação/Tese realizada em conformidade com a Portaria da CAPES n. 36, de 19 de março de 2020, de acordo com seu segundo artigo:*

*Art. 2o A suspensão de que trata esta Portaria não afasta a possibilidade de defesas de tese utilizando tecnologias de comunicação à distância, quando admissíveis pelo programa de pós-graduação stricto sensu, nos termos da regulamentação do Ministério da Educação."*

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **William Júnio de Lima, Usuário Externo**, em 12/08/2021, às 18:55, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Jose Dos Reis Vieira De Moura Junior, Orientador**, em 12/08/2021, às 21:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcos Napoleão Rabelo, Professor do Magistério Superior**, em 16/08/2021, às 14:28, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **STANLEY WASHINGTON FERREIRA DE REZENDE, Discente**, em 17/08/2021, às 16:48, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **2275926** e o código CRC **C40B4616**.

*Aos meus pais, Adriano e Luzia. Aos meus irmãos, Stéfany e Stanerty. Ao meu avô Antônio. In  
memorian às minhas avós, Aparecida e Maria.*

---

# Agradecimentos

---

Inicialmente, agradeço a Deus pelas oportunidades e experiências que pude vivenciar neste período da minha vida, pelo apoio e proteção que sempre me foi concedido e por ter me ajudado a ser uma pessoa melhor.

Aos meus pais, Adriano e Luzia, por me permitirem dedicar-me muitas vezes aos estudos de forma descompromissada com as outras áreas da vida, apoiando-me e confortando-me tanto financeiramente quanto emocionalmente, me dando todo carinho e amor que necessitava.

Aos meus irmãos, Stéfany e Stanerty, por todo apoio, carinho e conselhos que me deram, sendo meus alicerces e nos momentos mais difíceis.

Ao professor, orientador e amigo José dos Reis, pela disponibilidade, apoio e ensinamentos que sempre me deu desde o período da graduação. Sua dedicação e conhecimento aplicados em nossas conversas e pesquisas me ajudaram muito nos últimos anos, sempre me motivando a buscar nossos desafios para me aprimorar como pessoa e profissional. Muito obrigado por me permitir vivenciar essa experiência e por suas contribuições para este trabalho.

Ao meu amigo, Bruno Barella, que muito me ensinou nessa caminhada. Com seu apoio e companheirismo, consegui vencer mais esse desafio em minha vida. Amizade essa que será levada para a vida inteira.

Aos Prof. Dr. Celso Vieira Abud e Prof. Dr. Roberto Mendes Finzi Neto, pela disponibilidade e pelos ensinamentos que me proporcionaram durante a qualificação deste trabalho. Ao Prof. Dr. William Júnio de Lima pela disponibilidade e prontidão em participar da banca de defesa desta pesquisa, bem como pelos conselhos e contribuições prestados a este trabalho.

Ao Prof. Dr. Marcos Napoleão Rabelo, pelo apoio e por sempre ter acreditado nas minhas habilidades, por todos os conhecimentos que me passou em todas as aulas que tivemos desde a graduação. Agradeço também a sua disponibilidade em participar da banca de defesa deste trabalho.

A pós-doutoranda e pesquisadora Karine M. Tsuruta e ao Prof. Dr. Aldemir A. Cavalini Júnior pela colaboração e disponibilidade dos dados dos experimentos de máquinas rotativas.

Aos meus chefes e colegas de trabalho, Moisés, Fernanda, William Koga, Fabiana, Thaynara e Márcio pela oportunidade e companheirismo, por me possibilitarem melhorar socialmente e profissionalmente neste período.

Ao Programa de Pós-Graduação em Modelagem e Otimização da Universidade Federal de Goiás pela oportunidade de realizar este curso.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de pesquisa concedida ao autor desta dissertação de mestrado.

À todos aqueles que, de alguma forma, doaram um pouco de si para a realização desse trabalho.

*A menos que modifiquemos a nossa maneira de pensar, não seremos capazes de resolver os problemas causados pela forma como nos acostumamos a ver o mundo.*

*Albert Einstein*

# RESUMO

REZENDE, S. W. F. *Técnicas de Aprendizado Profundo Aplicadas ao Monitoramento de Integridade Estrutural por Impedância Eletromecânica*. 2021. 143 f. Dissertação (Mestrado em Modelagem e Otimização) – Unidade Acadêmica Especial de Matemática e Tecnologia, Universidade Federal de Goiás – Regional Catalão, Catalão – GO.

Neste trabalho é realizado um estudo das técnicas de monitoramento da integridade estrutural (SHM – *Structural Health Monitoring*), com foco principal na aplicação da metodologia SHM por impedância eletromecânica para caracterizar falhas estruturais em sistemas mecânicos. Essa metodologia geralmente combina sensores modernos com algoritmos inteligentes para identificar a presença de danos, observando alterações nos sinais monitorados e correlacionando-as com fenômenos físicos. Entretanto, quando essas variações são suficientemente complexas, torna-se necessário aplicar técnicas mais sofisticadas, capazes de abstrair informações pertinentes à condição de integridade estrutural. Nesse sentido, ferramentas inovadoras de aprendizado de máquina (em especial as Redes Neurais Artificiais - RNAs) vêm ganhando destaque, sendo extensivamente investigadas para se evitar erros no prognóstico estrutural e concentrando-se principalmente na análise de vibrações. Diante disso, o presente trabalho visa contribuir com a área de SHM, propiciando um aperfeiçoamento da técnica de impedância eletromecânica em termos da análise de integridade estrutural, associando-a à duas arquiteturas neurais (CNN e LSTM) para facilitar o processo de tomada de decisão. Assim, esta contribuição apresenta uma revisão bibliográfica de alguns dos principais conceitos associados a este tema, como materiais inteligentes, métodos de avaliação, o próprio método de impedância, os conceitos associados ao aprendizado de máquina e as arquiteturas neurais utilizadas. Em seguida, foram investigados quatro ensaios experimentais, empregando uma combinação do método da impedância com as respectivas arquiteturas CNN e LSTM para a identificação e/ou previsão de falhas estruturais. Assim, foi possível validar as metodologias propostas, verificando a sensibilidade das redes a algumas influências ambientais (como condições de temperatura e umidade) e operacionais (velocidade de operação e desbalanceamento) dos sistemas mecânicos em estudo. Como resultado, ambas as metodologias propostas são eficientes em termos de monitoramento da integridade estrutural, permitindo uma otimização do prognóstico estrutural.

**Palavras-chaves:** Monitoramento de Integridade Estrutural, Impedância Eletromecânica, Aprendizado Profundo, Redes Neurais Convolucionais, *Long Short-Term Memory*.

# ABSTRACT

REZENDE, S. W. F. *Deep Learning Techniques Applied to the Electromechanical Impedance-Based Structural Health Monitoring*. 2021. 143 f. Master Thesis in Modelling and Optimization – Unidade Acadêmica Especial de Matemática e Tecnologia, Universidade Federal de Goiás – Regional Catalão, Catalão – GO.

In this work, a study of structural health monitoring (SHM) techniques is carried out, with a primary focus on the application of the eletromechanical impedance-based SHM method to characterize structural failures in mechanical systems. This methodology generally combines modern sensors with intelligent algorithms to identify the presence of damage, observing changes in the monitored signals and correlating them with physical phenomena. However, when these variations are sufficiently complex, it becomes necessary to apply more sophisticated techniques, capable of abstracting information pertinent to the condition of structural health. In this sense, innovative machine learning tools (especially Artificial Neural Networks - RNA) have been gaining prominence, being extensively investigated to avoid errors in structural prognosis and focusing mainly on vibration analysis. Therefore, the present work aims to contribute to the SHM area, providing an improvement of the electro-mechanical impedance technique in terms of structural health analysis, associating it with two neural architectures (CNN and LSTM) to facilitate the decision-making process. Thus, this contribution presents a bibliographical review of some of the main concepts associated with this theme, such as intelligent materials, evaluation methods, the electromechanical impedance-based method itself, the concepts associated with machine learning techniques and the artificial neural networks used. Then, four experimental tests were investigated, employing a combination of the impedance-based method with the respective CNN and LSTM architectures for the identification and/or prediction of structural failures. Thus, it was possible to validate the proposed methodologies, verifying the sensitivity of the networks to some environmental influences (such as temperature and humidity conditions) and operational (operating speed and unbalanced) influences of the mechanical systems under study. As a result, both proposed methodologies are efficient in terms of the structural health monitoring, allowing an optimization of the structural diagnosis.

**Keywords:** Structural Health Monitoring, Electromechanical Impedance, Deep Learning, Convolutional Neural Networks, Long Short-Term Memory.

---

# LISTA DE FIGURAS

---

Figura 2.1 – Relações dos eixos de coordenadas do efeito piezoelétrico e do processo de polarização. . . . .	27
Figura 2.2 – Exemplos de pastilhas piezocerâmicas. . . . .	29
Figura 2.3 – Sensor de PVDF da série LDT1-028K, fabricado pela empresa Metrolog. . . . .	29
Figura 2.4 – Transdutor piezoelétrico de macro fibra. . . . .	30
Figura 2.5 – Etapas fundamentais ao monitoramento de integridade estrutural. . . . .	31
Figura 2.6 – Representação gráfica da inseparabilidade linear entre grupos de métrica de dano. . . . .	38
Figura 2.7 – Exemplo de análise qualitativa em assinaturas de impedância eletromecânica. . . . .	39
Figura 2.8 – Sistema de Aquisição de Assinaturas de Impedância - Modelo HP 4194A. . . . .	42
Figura 2.9 – Placa de aquisição de dados EVAL AD5933EBZ. . . . .	43
Figura 2.10 – Conversor PmodIA. . . . .	44
Figura 3.1 – Associação entre os temas de Inteligência Artificial, <i>Machine Learning</i> e <i>Deep Learning</i> . . . . .	47
Figura 3.2 – Representação gráfica do modelo <i>MP Neuron</i> . . . . .	49
Figura 3.3 – Função de ativação do neurônio artificial de McCulloch e Pitts. . . . .	50
Figura 3.4 – Representação gráfica do modelo <i>Perceptron</i> . . . . .	51
Figura 3.5 – Representação gráfica da rede neural MLP. . . . .	52
Figura 3.6 – Representação do Processo de <i>Dropout</i> . . . . .	62
Figura 3.7 – Esquematização de uma matriz de confusão para problemas de classificação multiclasse. . . . .	65
Figura 3.8 – Exemplo de representação de uma curva ROC. . . . .	66
Figura 4.1 – Representação gráfica da operação de <i>padding</i> em um vetor $x$ qualquer. . . . .	68
Figura 4.2 – Representação da operação matemática de convolução discreta. . . . .	69
Figura 4.3 – Arquitetura característica de uma rede neural convolucional unidimensional. . . . .	71
Figura 4.4 – Representação da conectividade esparsa em camadas convolucionais. . . . .	73

Figura 4.5 – Ilustração gráfica de campos receptivos locais e compartilhamento de parâmetros livres em redes neurais convolucionais. . . . .	74
Figura 4.6 – Abordagem de uma camada <i>pooling</i> pelo método de <i>MaxPooling</i> . . . . .	75
Figura 4.7 – Abordagem de uma camada <i>pooling</i> pelo método de <i>Average-Pooling</i> . . . . .	76
Figura 4.8 – Invariância das camadas <i>pooling</i> às transformações algébricas de imagens. . . . .	76
Figura 4.9 – Padronização de um <i>feature map</i> por meio de uma camada <i>flatten</i> . . . . .	77
Figura 5.1 – Exemplificação gráfica do processo de atraso na entrada de uma RNA. . . . .	80
Figura 5.2 – Representação do processo de recorrência em um neurônio artificial. . . . .	81
Figura 5.3 – Representação do fluxo de aprendizado em uma RNN. . . . .	81
Figura 5.4 – Esquematisação de uma célula LSTM. . . . .	84
Figura 6.1 – Estruturas utilizadas como objeto de estudo. . . . .	88
Figura 6.2 – Câmara Climática <i>Platinous EPL-4H</i> . . . . .	88
Figura 6.3 – Médias das assinaturas de impedância de cada grupo avaliado. . . . .	89
Figura 6.4 – Arquitetura neural convolucional implementada no experimento. . . . .	90
Figura 6.5 – Histograma com os resultados dos testes impostos a cada modelo. . . . .	95
Figura 6.6 – Vigas de aço utilizadas no experimento de corrosão por HCL. . . . .	97
Figura 6.7 – Médias das assinaturas de impedância de cada nível de severidade e seus respectivo valores de métrica RMSD. . . . .	99
Figura 6.8 – Arquitetura neural LSTM implementada no experimento. . . . .	100
Figura 6.9 – Relação entre os dados previstos pelos modelos neurais LSTM e os valores-alvo pré-delimitados. . . . .	101
Figura 7.1 – Sistema estrutural avaliado quanto a integridade estrutural sob diferentes condições de operação. . . . .	104
Figura 7.2 – Esquematisação das dimensões e posicionamento dos transdutores piezoelétricos em relação aos componentes do rotor. . . . .	105
Figura 7.3 – Anel deslizante e sistema de aquisição empregados na coleta das assinaturas de impedância. . . . .	105
Figura 7.4 – Condições de dano simuladas sobre o rotor. . . . .	106
Figura 7.5 – Médias das assinaturas de impedância coletadas para o PZT #1. . . . .	108
Figura 7.6 – Arquitetura neural convolucional usada no estudo de caso desta seção. . . . .	109
Figura 7.7 – Função de perda alcançada para o 13° modelo CNN do PZT #3 durante a sua etapa de treinamento. . . . .	113
Figura 7.8 – Matriz de Confusão dos valores previstos pela 13° execução modelo 1DCNN do PZT #3. . . . .	114
Figura 7.9 – Curva ROC dos valores previstos pela 13° execução modelo 1DCNN do PZT #3. . . . .	114
Figura 7.10 – Estratégia adotada no sequenciamento dos grupos de dados para a criação da série temporal utilizada nos modelos neurais LSTM. . . . .	117
Figura 7.11 – Arquitetura LSTM implementada no presente estudo de caso. . . . .	119

Figura 7.12 –Relação entre algumas previsões dos modelos LSTM implementados nesta seção. . . . .	121
--	-----

---

# LISTA DE TABELAS

---

Tabela 3.1 – Principais funções de perda utilizadas no treinamento de redes neurais artificiais. . . . .	59
Tabela 7.1 – Configurações experimentais adotadas para a obtenção das assinaturas de impedância do rotor. . . . .	107
Tabela 7.2 – Métricas alcançadas para as 20 repetições dos modelos 1DCNN para todos os PZTs avaliados. . . . .	112
Tabela 7.3 – Métricas alcançadas para as 20 repetições dos modelos LSTM para todos os PZTs avaliados. . . . .	120

---

# LISTA DE QUADROS

---

Quadro 2.1 – Classificação dos métodos de SHM quanto ao seu nível de abstração. . . .	33
Quadro 3.1 – Principais funções de ativação utilizadas em redes neurais artificiais. . . .	54
Quadro 6.1 – Sequenciamento das coletas e grupos de integridade avaliado na implementação do experimento. . . . .	98
Quadro 7.1 – Sequenciamento virtual dos estados de integridade adotados para a criação dos modelos neurais LSTM. . . . .	116

---

# LISTA DE ABREVIATURAS E SIGLAS

---

BTHC — *Balanced Temperature and Humidity Control*

BTT — *Backpropagation Through Time*

CCD — *Correlation Coefficient Deviation*

CEP — Código de Endereçamento Postal

CNN — *Convolutional Neural Network*

CPU — *Central Process Unit* / Unidade Central de Processamento

DL — *Deep Learning*

ELU — Unidade Linear Exponencial

EMI — *Electromechanical Impedance-based SHM Method* / Método de SHM baseado em Impedância Eletromecânica

GPU — *Graphics Processing Unit* / Unidade de Processamento Gráfico

HCL — Ácido Clorídrico

IA — Inteligência Artificial

IDE — *Integrated Development Environment* / Ambiente de Desenvolvimento Integrado

Leaky ReLu — Unidade Linear com Vazamento

LSTM — *Long Short-Term Memory*

LTU — *Linear Threshold Unit*

MFC — *Macro Fiber Composite*

ML — *Machine Learning*

MLP — *Multilayer Perceptron*

NDE — *Non-Destructive Evaluations*

PVDF — *Polyvinylidene Fluoride*

PZT — *Pb-Lead Zirconate Titanate* / Pastilha de Titanato Zirconato de Chumbo

ReLU — Unidade Linear Retificada

RMSD — *Root-Mean-Square Deviation*

RMSE — *Root-Mean-Square Error*

RMSprop — *Root-Mean-Square Propagation*

RNA — Redes Neurais Artificiais

RNN — *Recurrent Neural Network* / Redes Neurais Recorrentes

ROC — *Receiver Operating Characteristic Curve* / Curva Característica de Operação do Receptor

SHM — *Structural Health Monitoring*

TanH — Função Tangente Hiperbólica

---

# SUMÁRIO

---

1	INTRODUÇÃO . . . . .	20
1.1	Principais Objetivos e Contribuições do Trabalho . . . . .	23
1.2	Estrutura da Dissertação . . . . .	24
2	FUNDAMENTAÇÃO TEÓRICA SOBRE O MONITORAMENTO DE INTEGRI- DADE ESTRUTURAL . . . . .	26
2.1	Materiais Piezoelétricos - PZT . . . . .	26
2.2	Estratégia de Monitoramento da Integridade Estrutural . . . . .	30
2.3	Conceito de Impedância Eletromecânica . . . . .	33
2.4	SHM por Impedância Eletromecânica . . . . .	35
2.4.1	Métodos para avaliação direta do dano . . . . .	38
2.5	Sistemas de Aquisição para Coleta das Assinaturas de Impedância Ele- tromecânica . . . . .	41
2.5.1	Modelos <i>HP</i> . . . . .	41
2.5.2	Modelos baseados no Circuito Integrado (CI) AD5933 . . . . .	43
3	CARACTERIZAÇÃO BÁSICA DAS REDES NEURAS ARTIFICIAS . . . . .	45
3.1	Conceitos de <i>Machine Learning</i> e <i>Deep Learning</i> . . . . .	45
3.2	Tarefas realizadas em <i>Deep Learning</i> . . . . .	48
3.3	Conceito Geral de Redes Neurais Artificiais . . . . .	49
3.3.1	Funções de Ativação . . . . .	53
3.3.2	Formas de Aprendizagem Neural . . . . .	55
3.3.3	Processo de Treinamento das RNAs . . . . .	58
3.3.4	Regularização <i>Dropout</i> . . . . .	60
3.3.5	Maneiras de Avaliar a Eficácia de um Modelo Neural . . . . .	63
4	FUNDAMENTAÇÃO TEÓRICA SOBRE AS REDES NEURAS CONVOLUCI- ONAS . . . . .	67
4.1	Convolução Discreta . . . . .	67
4.2	Redes Neurais Convolucionais . . . . .	70
4.2.1	Camadas Convolucionais . . . . .	72
4.2.2	Camadas <i>Pooling</i> . . . . .	75
4.2.3	Camadas Totalmente Interligadas . . . . .	77

5	<b>FUNDAMENTAÇÃO TEÓRICA SOBRE A REDE LSTM</b> . . . . .	79
5.1	<b>Necessidade de Recorrência no âmbito da RNAs</b> . . . . .	79
5.2	<b>Redes Neurais Recorrentes</b> . . . . .	80
5.3	<b>Treinamento de uma RNN por <i>Backpropagation Through Time</i></b> . . . . .	82
5.4	<b>Arquitetura LSTM</b> . . . . .	83
6	<b>MODELAGEM COMPUTACIONAL DE TÉCNICAS DE APRENDIZAGEM PROFUNDA APLICADAS AO MONITORAMENTO DE INTEGRIDADE ESTRUTURAL</b> . . . . .	86
6.1	<b><i>Tensorflow</i></b> . . . . .	86
6.2	<b>Exemplificação da Implementação Computacional de uma CNN para à Detecção de Danos Estruturais em Assinaturas de Impedância Eletromecânica</b> . . . . .	87
6.2.1	<b>Procedimento Experimental</b> . . . . .	87
6.2.2	<b>Construção dos Modelos CNNs</b> . . . . .	90
6.2.3	<b>Resultados e Conclusões Prévias da Implementação</b> . . . . .	95
6.3	<b>Exemplificação da Implementação Computacional de uma rede LSTM para a Previsão da Severidade de Danos Estruturais em Vigas de Aço Sob Ação Corrosiva</b> . . . . .	97
6.3.1	<b>Procedimento Experimental</b> . . . . .	97
6.3.2	<b>Construção do Modelo LSTM</b> . . . . .	100
6.3.3	<b>Resultados e Conclusões Prévias da Implementação</b> . . . . .	101
7	<b>TÉCNICAS DE <i>DEEP LEARNING</i> SUPERVISIONADAS APLICADAS AO MONITORAMENTO DE INTEGRIDADE ESTRUTURAL DE UM SISTEMA ROTATIVO</b> . . . . .	103
7.1	<b>Detecção de Anomalias em Sistemas Rotativos usando a Arquitetura CNN</b> . . . . .	104
7.1.1	<b>Procedimento Experimental</b> . . . . .	104
7.1.2	<b>Construção dos Modelos CNNs</b> . . . . .	108
7.1.3	<b>Resultados e Análise do Estudo de Caso</b> . . . . .	111
7.2	<b>Predição da Condição de Integridade de Sistemas Rotativos usando a arquitetura LSTM</b> . . . . .	115
7.2.1	<b>Procedimento Experimental</b> . . . . .	115
7.2.2	<b>Construção do Modelo LSTM</b> . . . . .	118
7.2.3	<b>Resultados e Análise da Implementação dos Modelos Neurais LSTM</b> . . . . .	120
8	<b>CONSIDERAÇÕES FINAIS</b> . . . . .	123
8.1	<b>Conclusões da Pesquisa</b> . . . . .	123

**REFERÊNCIAS** ..... 127

## Capítulo 1

---

# Introdução

---

Falhas estruturais são problemas intrínsecos de engenharia e são suscetíveis à propagação devido a fatores externos e internos aos sistemas estruturais, tais como: variações climáticas, forças aplicadas, formas de carregamento, alterações das suas propriedades físicas e geométricas, tipo e intensidade de operação (MOURA JR, 2008; FRANCO, 2009; AVCI *et al.*, 2021). Deste modo, falhas desta natureza são comumente associadas a condições de desgaste, fadiga ou impacto das estruturas, sendo que para o bom funcionamento dos componentes mecânicos, elas devem ser identificadas e reparadas em tempo hábil, o que torna os processos de monitoramento de integridade um aspecto importante nos dias atuais.

Neste sentido, a manutenção de sistemas considerados críticos torna-se ainda mais fundamental, dados os impactos financeiros, ambientais e humanos causados por sua avaria inesperada (AFSHARI, 2012). Consequentemente, diferentes técnicas de inspeção têm sido pesquisadas, com vistas, principalmente, no alcance ou melhoria de quesitos como: segurança, operabilidade, minimização de custos de manutenção e reparo, eficiência logística, aumento do tempo de vida útil estrutural, entre outros (CHAUDHRY *et al.*, 1995; FRANCO, 2009; BAPTISTA; FILHO; INMAN, 2012; BAPTISTA *et al.*, 2014).

No entanto, como a modelagem direta das estruturas em estudo muitas vezes não é viável, dada a sua complexidade analítica, os pesquisadores têm favorecido o uso de técnicas de monitoramento de integridade estrutural, cujas quais compõe hoje o chamado *Structural Health Monitoring* (SHM) (CAVALINI JUNIOR, 2009).

Assim, o SHM pode ser considerado uma área multidisciplinar, que envolve diferentes abordagens experimentais a fim de estimar a presença de danos (FARRAR; LIEVEN; BEMENT, 2005; PALOMINO; STEFFEN JR; FINZI NETO, 2014). Para tanto, distintos *softwares* e *hardwares* são utilizados de forma a caracterizar os sistemas em estudo, adquirir e gerenciar os dados (estruturados e não-estruturados) de monitoramento, bem como avaliar, a longo prazo, as condições ambientais e operacionais desses sistemas.

O método de SHM por impedância eletromecânica (EMI - do inglês *Electromechanical Impedance-based SHM Method*), nesse contexto, apresenta-se como uma tecnologia pro-

missora para se reduzir riscos estruturais e custos de manutenção (UMESH T. *et al.*, 2018), sendo esta utilizada como foco principal do presente trabalho. Neste método, transdutores piezoelétricos são comumente acoplados às estruturas mecânicas e, posteriormente, um circuito eletrônico se torna responsável por monitorar a variação da impedância elétrica de cada pastilha, a uma dada frequência de excitação (MOURA JR, 2008; LEI *et al.*, 2009; BENTO, 2018; UMESH T. *et al.*, 2018).

Como cada transdutor piezoelétrico está acoplado (mecanicamente) à estrutura sob investigação, variações dos valores de impedância elétrica neste sugerem uma possível presença de dano estrutural (TSURUTA *et al.*, 2007). No entanto, para fazer uma medição correta de falha estrutural, o método necessita de um grande volume de dados (com resolução temporal e espacial dos estados de integridade) para avaliação, o que ocasiona em um aumento significativo da complexidade do processo de abstração (MAIO, 2011; GULGEC; TAKÁČ; PAKZAD, 2017).

Devido a esse aumento da complexidade computacional, vários trabalhos de SHM por impedância eletromecânica aplicaram, conjuntamente a seus experimentos, diferentes técnicas de abstração e classificação de padrões, a fim de delimitar uma relação desconhecida entre o estado atual de padrões estruturais e os diferentes estados históricos já observados (GULGEC; TAKÁČ; PAKZAD, 2017).

Tais técnicas de abstração são geralmente fornecidas como um processo de seleção e/ou classificação manual de recursos do conjunto de dados avaliado, sendo esse processo baseado principalmente em critérios ou conhecimentos técnicos especificados pelo operador do sistema (GULGEC; TAKÁČ; PAKZAD, 2017). Isto posto, e a fim de automatizar tal processo de seleção de recursos, diferentes técnicas de abstração de padrões têm sido desenvolvidas e implementadas nos últimos anos, que podem variar desde modelos simples, que utilizam poucos recursos computacionais e matemáticos para delimitar os principais componentes ou clusters dos dados avaliados, até mesmo sistemas robustos, envolvendo uma rede de nós de processamento para a realização automática da abstração de recursos (AVCI *et al.*, 2021).

Portanto, nesse contexto, as técnicas de aprendizado de máquina chamadas de Redes Neurais Artificiais (RNA) (em especial aquelas baseadas em aprendizagem profunda) ganharam destaque, sendo aplicadas a diversos estudos e panoramas para se identificar a existência de danos (JIANG; ZHANG; KOH, 2006).

Giurgiutiu e Kropas-Hughes (2003) empregaram em seu trabalho um algoritmo especializado na abstração de recursos principais, juntamente com o método de impedância eletromecânica e a arquitetura de rede neural MLP para identificar danos estruturais. Já Min *et al.* (2012) incorporaram a mesma arquitetura MLP com a técnica de impedância eletromecânica para identificar a influência prejudicial dos efeitos ambientais sobre o processo de identificação da presença de danos, para isso foi empregado etapas de pré-processamento

de dados e uma abstração prévia de recursos.

A aplicação de outros modelos de aprendizado de máquina, incluindo aqueles de aprendizagem profunda e que por sua vez são correlacionadas ao contexto de SHM também pode ser verificada em (KUDELA *et al.*, 2018), com diferentes recursos de processamento e técnicas computacionais e/ou matemáticas sendo empregados.

As RNAs, no entanto, são modelos matemáticos maciços que possuem a capacidade de aprender abstraindo repetidamente informações de dados históricos. Sua inspiração biológica, conforme o próprio nome sugere, se origina na representatividade do cérebro humano, sendo capaz de caracterizar diferentes estados e objetos a partir da variabilidade observada no ambiente (SALDARRIAGA *et al.*, 2009). Para tanto, todos os mecanismos de informação manipulados pelas RNAs são altamente paralelos, levando a um processamento de dados de alta ordem (JIANG; ZHANG; KOH, 2006; MIN *et al.*, 2012).

Segundo Veen e Leijnen (2019), existem várias topologias neurais já desenvolvidas, que vão desde mecanismos simples (compostos por até três camadas neurais) até arquiteturas densas (compostas por diversas camadas neurais) e que são aplicadas aos mais variados tipos de problemas da atualidade. Entretanto, em seu trabalho, (OLIVEIRA; MONTEIRO; FILHO, 2018) apontam que poucos estudos foram realizados com relação à aplicação das arquiteturas CNNs, agregada ao monitoramento da integridade estrutural por impedância eletromecânica, sendo que os únicos trabalhos existentes utilizaram imagens como entrada para o modelo pré-processado, o que causa um aumento no custo computacional.

Um condicionamento semelhante pode ser considerado em relação aos estudos da arquitetura *Long Short-Term Memory* (LSTM) no que diz respeito a detecção de falhas estruturais, porém com alguns avanços quanto à sua aplicabilidade no âmbito das pesquisas de SHM (LEI; LIU; JIANG, 2019; LIN; LIU; ZHOU, 2019). Isso é decorrente devido a capacidade de tal arquitetura em solucionar alguns problemas típicos de análise temporal, em que modelos recorrentes são ineficientes, mas necessários.

Assim, este trabalho visa contribuir com as áreas de SHM e Inteligência Artificial, avaliando duas possíveis vertentes de integração entre os modelos de aprendizagem profunda e o método de monitoramento baseado em impedância eletromecânica. Para tanto, diferentes modelos serão implementados ao decorrer desta dissertação, os quais foram baseados nas arquiteturas CNN e LSTM.

Durante o trabalho foram avaliados quatro testes experimentais, dos quais apenas dois foram aplicados em relação a cada uma das arquiteturas neurais estudadas. Assim, foi possível validar as metodologias impostas, verificando a sensibilidade das redes a algumas influências ambientais (como condições de temperatura e umidade) e operacionais (velocidade de operação e desbalanceamento) dos componentes, permitindo o desenvolvimento de uma metodologia sensível e independente a tais fatores, podendo assim ser aplicável ao

escopo do monitoramento de integridade estrutural.

Assim, pretende-se, com o desenvolvimento desta metodologia, disseminar e aprimorar o SHM no âmbito das linhas de pesquisa da Universidade Federal de Goiás – Regional Catalão, ampliando a técnica de impedância eletromecânica e produzindo meios confiáveis para identificar a presença de danos.

## 1.1 Principais Objetivos e Contribuições do Trabalho

Embora as técnicas de SHM tenham sido amplamente utilizadas na literatura para se monitorar estruturas metálicas e/ou compósitas, existe ainda uma escassez em relação à sua aplicação e formas de tratamento, juntamente com algoritmos de aprendizagem profunda, para auxiliar no diagnóstico estrutural (OLIVEIRA; MONTEIRO; FILHO, 2018).

Esse paradigma, até então, se torna ainda mais evidente quando se trata do acoplamento entre o método SHM por impedância eletromecânica e as arquiteturas neurais LSTM e CNN, uma vez que nos estudos atuais (envolvendo esses componentes) são impostas limitações quanto ao uso de dados de monitoramento, o que incentiva novas pesquisas para se melhorar a técnica. Assim, o presente trabalho visa contribuir com a área da seguinte forma:

- ✓ Propondo novas abordagens do método de monitoramento da integridade estrutural baseado em impedância eletromecânica, combinando tal técnica não-destrutiva com arquiteturas neurais de aprendizagem profunda (*Deep Learning*) para auxiliar a posterior tomada de decisão quanto à integridade estrutural de sistemas mecânicos.
- ✓ Utilizando ferramentas de baixo custo para aplicar as metodologias propostas em cada um dos experimentos analisados nesta contribuição, a fim de melhorar suas relações de custo-benefício.
- ✓ Desenvolvendo aplicações e modelos de rede neural convolucional (ou LSTM) que sejam estáveis para monitorar, nas condições aqui apresentadas, a integridade estrutural dos sistemas mecânicos. Assim, os modelos desenvolvidos ao longo da dissertação são assertivos o suficiente para que influências externas e internas ao funcionamento das estruturas monitoradas não prejudiquem sua capacidade de identificar a presença de danos estruturais.
- ✓ Empregando uma menor quantidade de etapas de processamento (como técnicas de compensação da temperatura e conversão de sinais) nos dados de entrada de cada modelo neural. Porém adicionando maiores quantidades de informações relativas aos sinais de impedância na construção dos modelos neurais. Isto proporciona uma maior veracidade nos resultados encontrados pelas metodologias impostas.
- ✓ Desenvolvendo aplicações significativas para o monitoramento de integridade estrutural, utilizando arquiteturas de *deep learning* como forma de abstração e avaliação da

presença de falhas estruturais em sistemas mecânicos. Assim, quesitos de manutenção programada poderão ser otimizados, auxiliando tanto o setor produtivo quanto o de planejamento.

## 1.2 Estrutura da Dissertação

A fim de tornar a fundamentação teórica deste trabalho mais clara e concisa, o mesmo foi subdividido em capítulos da seguinte forma:

O Capítulo 1 discute brevemente a importância dos estudos de SHM para garantir melhores requisitos de segurança e economia, além de apontar os principais métodos e ferramentas que serão utilizados no desenvolvimento deste trabalho. Neste capítulo, também são abordados os principais objetivos e contribuições desta pesquisa, finalizando com a descrição da estrutura utilizada na dissertação.

O Capítulo 2 aborda os principais conceitos que envolvem o método de impedância eletromecânica, descrevendo fundamentos como: materiais piezoelétricos, estratégia de monitoramento de integridade estrutural, acoplamento eletromecânico, métodos diretos para avaliação de danos, principais sistemas de aquisição e o próprio processo de monitoramento da integridade estrutural por impedância eletromecânica.

O Capítulo 3 abrange as características superficiais do aprendizado de máquina, incluindo as principais tarefas de aprendizagem profunda relacionadas ao contexto desta pesquisa. Nele também é realizada uma introdução ao histórico e principais componentes das redes neurais artificiais, sendo discutido quesitos como: formas de aprendizado, treinamento, funções de ativação e métricas comumente utilizadas na avaliação de modelos neurais.

Os Capítulos 4 e 5 tratam, respectivamente, das formulações teóricas dos modelos neurais CNN e LSTM, descrevendo sua estrutura, componentes, fluxos e formas de abstração da informação.

O Capítulo 6 expõe modelagens computacionais introdutórias da metodologia desenvolvida, cobrindo os recursos e métodos usados individualmente para cada arquitetura. Neste, é realizado também uma avaliação prévia dos resultados da aplicação de cada modelo no âmbito do monitoramento de integridade estrutural, descrevendo um primeiro panorama de aplicação destes modelos bem como a sua eficiência quanto a identificação de falhas.

O Capítulo 7 tem a parte prática desta pesquisa sendo realizados diferentes testes experimentais com o objetivo de validar o uso de cada arquitetura neural aqui utilizada (CNN e LSTM). Dessa forma, foi possível sustentar a hipótese defendida, em que se busca verificar a aplicabilidade de tais redes neurais em apoio ao monitoramento da integridade estrutural

baseado em impedância eletromecânica. Para isso, são apresentados os recursos e componentes necessários a cada estudo de caso, de forma a possibilitar sua reprodutibilidade. Os resultados obtidos em cada experimento também são descritos e explicados de forma assertiva.

O Capítulo 8 finaliza o trabalho descrevendo as conclusões gerais da abordagem imposta, apontando sua eficácia, empregabilidade e principais características destacadas. Além disso, é feita uma síntese das principais contribuições observadas, permitindo a delimitação de aspectos ainda passíveis de verificação e estudos futuros.

## Capítulo 2

---

# Fundamentação Teórica sobre o Monitoramento de Integridade Estrutural

---

Neste capítulo, são abordados alguns conceitos básicos relacionados ao monitoramento de integridade estrutural por impedância eletromecânica, cobrindo uma breve descrição dos materiais piezoelétricos, bem como a estratégia utilizada no monitoramento da integridade estrutural.

Ao final, uma formulação teórica do método de SHM por impedância eletromecânica é apresentada, especificando suas concepções e as ferramentas necessárias para o desenvolvimento do trabalho.

## 2.1 Materiais Piezoelétricos - PZT

Os componentes piezoelétricos têm sido empregados de forma eficiente em diversas áreas do conhecimento (MOURA JR, 2008; MAIO, 2011; MISHRA; JAIN; PRASAD, 2015; SAFAEI; SODANO; ANTON, 2019). Isto decorre do fato destas semiestructuras possuírem baixo custo de fabricação e dimensões reduzidas, o que somado a um baixo consumo de energia operacional os tornam atrativos em aplicações de engenharia (KOBAYASHI *et al.*, 2009).

Os materiais piezoelétricos são exemplos de “estruturas inteligentes” que possuem a capacidade de transformar, pela alteração de suas propriedades físicas, uma forma de energia em outra (PARK; INMAN, 2001). Consequentemente, a sua utilização em sistemas de monitoramento e/ou de controle objetiva a construção de equipamentos adaptativos, capazes de relacionarem em único fluxo processual diferentes grandezas físicas (OLIVEIRA, 2013).

De acordo com Afshari (2012) a piezeletricidade foi formulada pelos irmãos Jacques

e Pierre Curie, no final do século XIX. Os irmãos Curie identificaram que certos materiais ao serem expostos a campos de tensão elétrica em elevadas temperaturas apresentavam uma pequena deformação de suas dimensões iniciais, o chamado comportamento piezoelétrico (AFSHARI, 2012).

As propriedades piezoelétricas, nesse sentido, podem ser estabelecidas por meio de três eixos de direção, dois dos quais consistem em direções isotrópicas (onde as propriedades são semelhantes em todos os pontos nessas direções) e o outro está relacionado à direção de polarização, a qual é dependente do efeito piezoelétrico conforme mostrado na Figura 2.1 (TEBALDI; COELHO; JUNIOR, 2006).

Figura 2.1 – Relações dos eixos de coordenadas do efeito piezoelétrico e do processo de polarização.



Fonte: Adaptado de Bento (2018).

Em geral, os transdutores piezoelétricos são feitos a partir da polarização dos dipolos de um material piezoelétrico enquanto este material está sujeito a altos campos elétricos e altas temperaturas (normalmente superiores a temperatura de *Curie*, que é a temperatura na qual o material perde espontaneamente sua polarização inicial, possibilitando assim a sua posterior repolarização induzida de forma a viabilizar as suas propriedades dielétricas) (TEBALDI; COELHO; JUNIOR, 2006; BAPTISTA *et al.*, 2014). Dito isso, observa-se na literatura que compósitos ou substratos anisotrópicos e normalmente ortotrópicos são adequadamente selecionados, devido às suas estruturas reticuladas poliméricas, cerâmicas ou cristalinas que lhes permitem alinhar parcialmente seus dipolos elétricos, resultando assim em uma polarização macroscópica que lhes permite um acoplamento eletromecânico muito mais eficiente (BANKS; SMITH; WANG, 1996; MOURA JR, 2008; BENTO, 2018).

Assim, é tido como material piezoelétrico todo aquele que possui a capacidade de converter diferentes potenciais elétricos em esforços mecânicos (e/ou vice-versa), em faixas de temperaturas inferiores a respectiva temperatura de *Curie* do material piezoelétrico considerado (BIRMAN, 1996; LU *et al.*, 2017). Neste contexto, a formação de uma diferença de potencial entre dípolos de um transdutor piezoelétrico, quando este é submetido a uma deformação mecânica, é nomeada de efeito piezoelétrico direto. Ao passo que, a deformação mecânica do transdutor, por imposição de uma diferença de potencial, é chamada de efeito piezoelétrico inverso (RABELO, 2014). Nesse contexto, torna-se possível evidenciar que as relações constitutivas da piezeletricidade são precedentes da energia total do sistema, ou seja, é possível compreender as relações fenomenológicas dos efeitos piezoelétricos em um

sistema eletromecânico (FU; COHEN, 2000; LIMA, 2013; RABELO, 2014).

Entretanto, mesmo que as respostas de tais aplicações estruturais sejam muito próximas à linearidade, ao se realizar procedimentos em elevados níveis de excitação, isto é, em altas frequências, os elementos piezoelétricos podem ainda demonstrar características não-lineares. Dessa forma, as aplicações envolvendo a piezeletricidade são, usualmente, restritas as leis lineares formuladas por Voigt, onde os efeitos direto e inverso são descritos de acordo com as equações (2.1) e (2.2), respectivamente (PALOMINO *et al.*, 2008; FRANCO, 2009),

$$D_m = \epsilon_{mn}^T E_n + d_{mkl} \sigma_{kl} \quad (2.1)$$

$$e_{ij} = s_{ijkl} \sigma_{kl} + d_{mij}^T E_m \quad (2.2)$$

sendo que  $D$  e  $E$  representam o vetor deslocamento ( $C/m^2$ ) e o vetor campo elétrico ( $N/m^2$ ) sofridos pela pastilha PZT;  $\epsilon$  e  $d$  são o tensor dielétrico ( $m/V$ ) do material e o tensor de tensão piezolétrica ( $F/m$ ), enquanto que a deformação mecânica do material é relacionada com a tensão  $\sigma$  através do tensor longitudinal  $s$  aplicado ( $m^2/N$ ). Os demais caracteres decorrem da notação indicial, a qual distingue o direcionamento de cada componente do efeito piezoelétrico.

Convém observar nos materiais piezoelétricos dois fatores. O primeiro é que tais materiais após polarizados, os mesmos não devem ultrapassar novamente a sua respectiva temperatura de *Curie*, dado que eles podem perder sua polarização inicial e por conseqüente sua propriedade piezolétrica (ZHANG; YU, 2011). Já o segundo fator, é que as características do efeito direto permitem a sua utilização como sensor, à medida que a propriedade decorrente ao efeito inverso permite a descrição do dispositivo como atuador (ISLAM; HUANG, 2016).

No entanto, para realizar a identificação de falhas, o acoplamento eletromecânico de tais componentes deve ser projetado de forma a não influenciar significativamente a resposta dinâmica do sistema estrutural, garantindo a veracidade do processo de medição e detecção de danos (RABELO *et al.*, 2017b).


Dentre os principais tipos de materiais piezoelétricos presentes na literatura e que, posteriormente, têm sido amplamente utilizados no diagnóstico de falhas estruturais estão: as pastilhas piezocerâmicas (compostas por titanato-zirconato de chumbo), os piezopolímeros (conhecidos como fluorido de polivinilideno – PVDFs) e os compósitos de macro fibras (MFCs – do inglês *Macro Fiber Composites*).

Por se tratar de um material cerâmico, as pastilhas PZTs possuem uma rigidez geralmente superior à da estrutura em que se encontram acopladas, o que ocasiona em uma conversão eletromecânica de grande eficácia. Assim, esses materiais tem apresentado grande aplicabilidade em métodos de monitoramento, servindo como atuadores auto-sensíveis (ALLEN; PEAIRS; INMAN, 2004; MOURA JR; STEFFEN JR, 2004; MOURA JR, 2008; TSURUTA *et al.*, 2017).

Ainda, deve-se destacar que os componentes piezocerâmicos possuem outros tipos de características que os tornam atrativos em aplicações de inspeção e controle, tais como: uma ampla faixa de linearidade, um alto fator de acoplamento eletromecânico, rápida resposta à estímulos externos, diversas geometrias de confecção, baixo peso e custo de fabricação reduzido.

A Figura 2.2 apresenta alguns modelos de pastilhas piezoelétricas (MONTANEZ, 2019). Em geral, essas pastilhas são confeccionadas na forma de discos ou anéis piezoelétricos, sendo revestidas, em ambas as faces, por um condutor metálico de polarização, que é utilizado para acoplar o transdutor ao sistema de aquisição de dados.

Figura 2.2 – Exemplos de pastilhas piezocerâmicas.




Fonte: Retirado de Montanez (2019).

Já os polímeros de PVDF (do inglês *Polyvinylidene Fluoride*) possuem uma maior maleabilidade em relação as pastilhas piezocerâmicas e, também, uma superior elasticidade se comparados as estruturas de engenharia comuns. Assim, embora esses materiais possam ser confeccionados com geometrias muito mais atrativas do que à das pastilhas PZTs (obtendo espessuras de cerca de 40 a 120 $\mu m$ ), o seu emprego como atuadores torna-se ineficiente (ODON, 2003; FRANCO, 2009).

Por outro lado, além de seu custo de fabricação ser menor, os potenciais dielétricos alcançados por esses componentes são, aproximadamente, vinte vezes maiores do que a das pastilhas PZTs, sendo assim, eles são muito mais sensíveis a modificações externas (RABELO, 2014). A Figura 2.3 apresenta um exemplo de sensor PVDF da série LDT1-028K.


Figura 2.3 – Sensor de PVDF da série LDT1-028K, fabricado pela empresa Metrolog.



Fonte: Retirado de Metrolog (2020).

Por último, os materiais de MFC são caracterizados por serem flexíveis e de alta resistência, sendo tolerantes a alguns tipos de danos e ambientes extremos (BENTO, 2018). Estes componentes estruturais são compostos por fibras piezoelétricas retangulares, intercaladas entre camadas de adesivo e filme de eletrodo de poliimida (NASA, 2007). A Figura 2.4 apresenta um exemplo de componente MFC.

Figura 2.4 – Transdutor piezoelétrico de macro fibra.



Fonte: Retirado de Nasa (2020).

A característica flexível e alta durabilidade dos MFCs os tornam atrativos em aplicações que requerem geometria complexa, tais como o monitoramento de asas e painéis de avião (NASA, 2007). No entanto, nesta contribuição será empregado apenas às pastilhas piezocerâmicas (PZTs) para o monitoramento de integridade estrutural por impedância eletromecânica. A escolha destes materiais é decorrente da sua versatilidade, disponibilidade e histórico de uso.

Park *et al.* (1999) acoplou transdutores piezoelétricos em estruturas compósitas para monitorar sua integridade estrutural e, posteriormente, esse procedimento foi reproduzido em outros trabalhos da literatura, a fim de se monitorar diversos tipos de estrutura e panoramas de utilização (ALLEN; PEAIRS; INMAN, 2004; MOURA JR; STEFFEN JR, 2004; MOURA JR; STEFFEN JR, 2006; FRANCO, 2009; HU; ZHU; WANG, 2014; SILVA *et al.*, 2016; TSURUTA *et al.*, 2017; BENTO, 2018; TALAKOKULA; BHALLA; GUPTA, 2018).

## 2.2 Estratégia de Monitoramento da Integridade Estrutural

Os métodos de SHM, de uma forma geral, possuem a capacidade de detectar alterações nas propriedades físicas de sistemas mecânicos, as quais podem sugerir a presença de danos (MOURA JR, 2008; TSURUTA *et al.*, 2007). Assim, esses métodos de monitoramento, comumente, são utilizados para apoiar a gerência do ciclo de vida estrutural e englobam, em sua maioria, as fases de aquisição, filtragem, validação e análise de dados (FARRAR; WORDEN, 2007; MAIO, 2011).

O processo de monitoramento, nas circunstâncias do SHM, envolve à observação periódica das estruturas em estudo, sendo que a partir de sinais obtidos pelo sensoriamento é realizado a extração de características sensíveis ao dano (RABELO *et al.*, 2017a).

O princípio básico utilizado é que a presença de dano influencia nas propriedades fi-

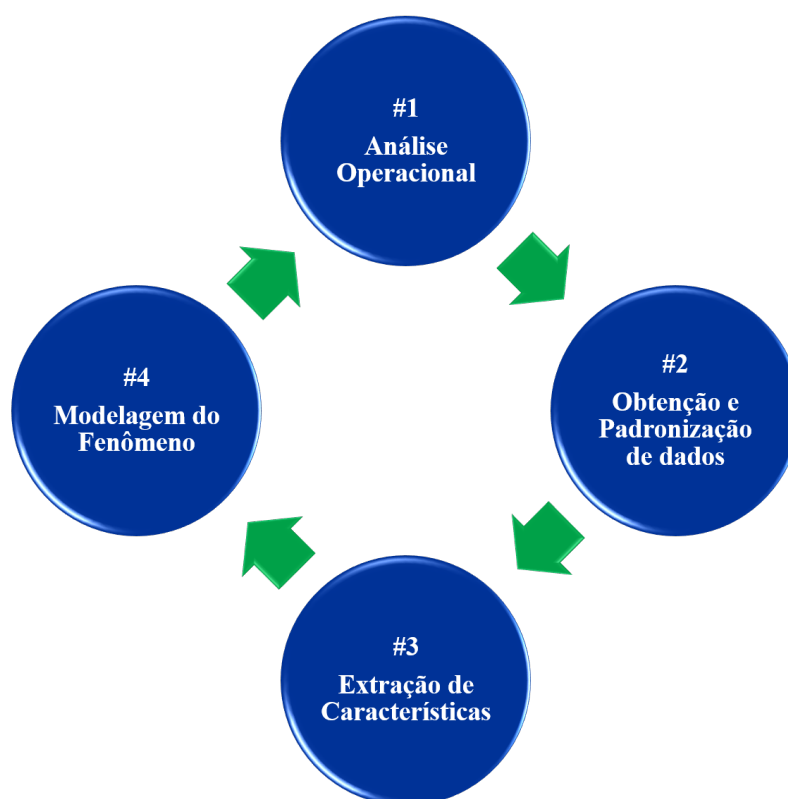
sicas e/ou geométricas das estruturas, como a rigidez, massa, os padrões de dissipação de energia, as condições de contorno e a conectividade do sistema. Todos estes elementos podem comprometer de forma negativa no desempenho final de cada estrutura, ocasionando em uma alteração na sua resposta dinâmica.

Assim, para a identificação do dano, os métodos de SHM geralmente realizam à comparação de dois estados fundamentais das estruturas analisadas, ou seja, a condição de estado íntegra e a condição de estado com falha (SARAVANAN; GOPALAKRISHNAN; RAO, 2015).

Seguindo a definição de Farrar e Worden (2007) existem quatro etapas fundamentais para se descrever um processo de monitoramento da integridade estrutural. Estas, por sua vez, se correlacionam de acordo com a Figura 2.5.

Na primeira etapa, é verificado a capacidade do sistema em identificar danos, ou seja, são averiguados os requisitos mínimos e a aptidão do monitoramento da integridade estrutural. Para isso, faz-se necessário a definição de certas variáveis do problema, tais como as condições ambientais, a capacidade do sistema de aquisição e o tipo de falha a ser monitorada.

Figura 2.5 – Etapas fundamentais ao monitoramento de integridade estrutural.



Fonte: O autor (2021).

Já a segunda etapa é baseada na aquisição e na normalização dos dados de monitoramento, sendo determinado técnicas e métodos para minimizar as influências intrínsecas do problema, tais como os métodos de compensação da temperatura e a filtragem de dados.

Deve-se verificar que, nesta etapa é realizado uma abstração prévia dos dados de monitoramento, sendo empregado técnicas que estão em constante aperfeiçoamento na literatura.

A extração de características (terceira etapa apresentada) é uma das áreas do SHM que tem recebido um especial interesse nas últimas décadas, principalmente devido ao desenvolvimento tecnológico e a expansão de modelos matemáticos para os limites do *Big Data*<sup>1</sup>. Sua composição se dá pelo emprego de ferramentas e técnicas de *Data Mining*<sup>2</sup> e Inteligência Artificial (IA), de modo a descrever classes e/ou padrões que auxiliem o prognóstico estrutural.

A modelagem do fenômeno, por sua vez, se baseia na descrição formal do problema, em que se é aplicado algoritmos (computacionais e/ou matemáticos) para delimitar estatisticamente os níveis de integridade do sistema.

Maio (2011) expõe duas abordagens para se descrever um problema de monitoramento da integridade estrutural. A primeira é caracterizada pela modelagem direta da estrutura em estudo, sendo esse modelo posteriormente confrontado com dados experimentais para se delimitar a presença de danos. Tal abordagem, conhecida como problema direto, é comumente utilizada em estruturas simples (de geometria básica e composição homogênea), devido à sua facilidade analítica.

Já a segunda abordagem realiza a detecção de falhas por intermédio da comparação de sinais da estrutura, os quais são adquiridos em momentos distintos. Deste modo, a divergência entre os sinais coletados é responsável por indicar a presença de dano, sendo que nessa concepção, conhecida como problema inverso, um modelo matemático estrutural não é factível (seja pela complexidade geométrica da estrutura ou dimensões dos dados de monitoramento).

Ainda, convém observar que por meio de uma correta modelagem do problema, torna-se possível minimizar os equívocos de diagnóstico, como os falsos-positivos (que é a indicação de falha quando não há) e os falsos-negativos (que é a não identificação do dano quando o mesmo existe) (GONSALEZ, 2012).

Ademais, durante a modelagem do problema, métricas baseadas em certas características do sistema podem ser utilizadas a fim de se quantificar o dano quanto à sua existência, localização, tipo e severidade. Assim, os métodos de SHM podem ser usualmente classificados quanto ao seu nível de abstração e/ou complexidade de execução.

Uma das mais conceituadas classificações para os métodos de SHM foi inicialmente desenvolvida por Doebling *et al.* (1998) e, posteriormente, expandida por Inman (2001). Esta

<sup>1</sup> *Big Data* – É um termo que se refere ao uso de grandes quantidades de dados, estruturados e/ou não-estruturados, para se obter informações a respeito de determinado assunto. Nesse sentido, associa-se conceitos tais como o volume, a variedade e a velocidade de processamento de dados.

<sup>2</sup> *Data Mining* – É definido como um processo não-trivial de extração de características em um grande volume de dados. Para isso, comumente, é aplicado técnicas de agrupamento, hipóteses e outras, de modo a identificar padrões consistentes.

classificação descreve os métodos de SHM de acordo com o Quadro 2.1.

Nível	Descrição
#1	Detecta a existência de falha.
#2	Detecta e localiza a falha.
#3	Detecta, localiza e caracteriza a falha.
#4	Detecta, localiza, caracteriza e estima a vida útil da estrutura.
#5	Combina o nível #4 com materiais inteligentes para autodiagnóstico estrutural.
#6	Combina o nível #4 com materiais inteligentes para auto-reparo estrutural.
#7	Combina o nível #1 com materiais inteligentes para controle ativo do sistema.

Fonte: O autor (2021).

Quadro 2.1 – Classificação dos métodos de SHM quanto ao seu nível de abstração.

Ressalta-se no Quadro 2.1 que os últimos níveis são diretamente vinculados a integridade do sistema após a identificação do dano, seja para o seu controle ativo, reparo ou estimativa do tempo de vida útil. Assim, as técnicas não destrutivas (NDEs – do inglês *Non-Destructive Evaluations*) têm sido amplamente estudadas nos últimos anos, a fim de se garantir a integridade estrutural e uma menor interferência do homem no processo de monitoramento (BRAY; MCBRIDE, 1992).

Entretanto, os métodos de NDEs tradicionais se baseiam em processos visuais e/ou experimentais, tais como a aplicação de ondas acústicas, campos magnéticos, radiografias, líquidos penetrantes e outros. Esses processos geralmente requerem uma etapa de inspeção do operador (seja para a identificação do melhor local de monitoramento ou a abstração de informações críticas ao problema), não sendo assim usuais em estruturas de difícil acesso ou de monitoramento contínuo (BRAY; MCBRIDE, 1992).

A partir de então, os métodos de SHM ganharam destaque, sendo passíveis de análise no domínio do tempo, no da frequência ou modal. Todavia, ressalta-se que em todos esses métodos, a aquisição dos dados de monitoramento é realizada apenas no domínio tempo, sendo estes, convertidos então, para os outros domínios conforme a sua necessidade (MARQUI, 2007).

Ademais, salienta-se que dentre os métodos SHM, aqueles que empregam o domínio frequencial (em especial o método de impedância eletromecânica) apresentam-se como os mais atrativos na literatura, visto que a presença de dano por esses métodos de monitoramento é facilmente interpretada (MOURA JR; STEFFEN JR, 2006).

## 2.3 Conceito de Impedância Eletromecânica

Conforme Tsuruta *et al.* (2007) a técnica de monitoramento por assinaturas de impedância se baseia no chamado acoplamento eletromecânico, o qual é resultante da incorporação de transdutores piezoelétricos à estrutura monitorada. Dessa forma, a determinação

da função de resposta do sistema é dependente tanto das características elétricas do transdutor (dada pela impedância elétrica) quanto das características físicas do sistema estrutural (dada pela impedância mecânica).

A impedância elétrica pode ser conceituada como o valor total da carga resistiva que um circuito oferece à passagem de corrente alternada, sendo essa carga uma grandeza vetorial composta por dois componentes principais: a resistência elétrica e a reatância.

Assim, nesse contexto, é determinada por resistência elétrica o grau de oposição que um sistema apresenta ao seu próprio fluxo de corrente, exibindo comportamento similar em circuitos de corrente contínua e circuitos de corrente alternada (HAYT JR; KEMMERLY; DURBIN, 2014).

O valor da resistência de um componente elétrico pode ser calculado de acordo com a lei de *Ohm*, a qual o define como a razão entre a tensão fornecida ao circuito e a corrente que passa por esse mesmo sistema (HAYT JR; KEMMERLY; DURBIN, 2014). Deste modo, a resistência elétrica caracteriza-se por assumir apenas valores positivos e pode ser obtida conforme a equação (2.3),

$$R_e = \frac{V_e}{I_e} \quad (2.3)$$

onde  $R_e$  representa a resistência elétrica do circuito,  $V_e$  é a tensão elétrica fornecida e  $I_e$  é o valor da corrente imposta.

A reatância de um circuito elétrico, diferentemente da resistência, pode assumir tanto valores positivos quanto negativos, sendo essa dualidade determinada pelo tipo de componente (capacitor ou indutor) pelo qual ela é calculada (RABELO, 2014). Ainda, destaca-se nessa formulação, que a reatância não é igualmente aplicável a circuitos de corrente contínua bem como sua composição em circuitos de corrente alternada não dissemina energia na forma de calor (HAYT JR; KEMMERLY; DURBIN, 2014).

Quando a reatância assume valores positivos ela é chamada de reatância indutiva ( $X_L$ ), sendo o seu valor expresso em *Ohms* ( $\Omega$ ) conforme a equação (2.4),

$$X_L = 2 \cdot \pi \cdot \omega_e \cdot L \quad (2.4)$$

onde  $L$  representa a indutância do sistema (em *Henries* –  $H$ ) e  $\omega_e$  a frequência de excitação do circuito considerado (em *Hertz* –  $Hz$ ). Em contrapartida, quando a reatância assume valores negativos ela é chamada de reatância capacitiva ( $X_C$ ), sendo o seu valor dado pelo inverso da reatância indutiva, conforme é descrito na equação (2.5),

$$X_C = \frac{1}{2 \cdot \pi \cdot \omega_e \cdot C} \quad (2.5)$$

onde  $C$  representa a capacitância do sistema considerado, cuja qual à unidade no SI é dada por *Farad* ( $F$ ).

Por outro lado, a impedância mecânica de um sistema estrutural pode ser compreendida como a razão entre força harmônica aplicada e a velocidade linear resultante, sendo esse último componente avaliado na mesma direção da força imposta e no seu ponto de aplicação em relação a estrutura. Assim, ela é uma grandeza vetorial (composta por módulo e ângulo de fase) que pode ser expressa de acordo com a equação (2.6),

$$Z_m = \frac{f}{\vec{v}(t)} \quad (2.6)$$

onde  $Z_m$  representa a impedância mecânica do sistema,  $f$  é a força harmônica aplicada em um ponto da estrutura e  $\vec{v}(t)$  é a velocidade com que esse ponto se desloca.

A impedância mecânica representa o quanto uma determinada estrutura resiste ao movimento de uma força aplicada, sendo essa grandeza ainda afetada pela frequência de excitação do sistema, ou seja, a impedância mecânica é mais sensível nos picos de ressonância (PALOMINO *et al.*, 2008).

Consequentemente, pode-se conceituar o termo “impedância eletromecânica” como sendo o acoplamento das duas formulações anteriormente citadas, compreendendo ao mesmo tempo a aquisição da impedância elétrica do transdutor e a medição da impedância mecânica do sistema estrutura/PZT.

Assim, através dos valores de impedância, as variações de rigidez e/ou amortecimento da estrutura podem ser monitoradas (TSURUTA *et al.*, 2007). Uma vez que os valores de rigidez e amortecimento estão intimamente interligados a integridade do sistema, torna-se factível o uso de ferramentas numéricas e estatísticas para a definição do dano.

## 2.4 SHM por Impedância Eletromecânica

A abordagem teórica que propõe o uso da impedância eletromecânica como técnica para o monitoramento de integridade estrutural foi inicialmente proposta por Liang, Sun e Rogers (1997a), sendo esta posteriormente aperfeiçoada em outros trabalhos da literatura (PARK *et al.*, 1999; GIURGIUTIU; ZAGRAI, 2000; SOH *et al.*, 2000; GIURGIUTIU; ZAGRAI; BAO, 2002; ALLEN; PEAIRS; INMAN, 2004; MOURA JR; STEFFEN JR, 2004; MOURA JR; STEFFEN JR, 2006; FRANCO, 2009; HU; ZHU; WANG, 2014; SILVA *et al.*, 2016; TSURUTA *et al.*, 2017; BENTO, 2018; TALAKOKULA; BHALLA; GUPTA, 2018).

A formulação básica do método consiste em um problema inverso, no qual é monitorado as variações das respostas dinâmicas das estruturas em estudo, a fim de se delimitar a presença de danos. Assim, para que uma falha seja identificada, faz-se necessário confrontar estatisticamente o estado de integridade atual do sistema com os seus padrões históricos de referência, sendo delimitado índices ou evidências que mensurem o dano (ALLEN; PEAIRS; INMAN, 2004).

No entanto, como a aquisição direta da impedância mecânica de um sistema físico

é inviável, o método normalmente emprega transdutores piezoelétricos incorporados (ou acoplados) a ele (TSURUTA *et al.*, 2017). Esses materiais destinam-se a excitar e coletar simultaneamente as respostas dinâmicas das estruturas, sendo que dessa forma, por meio de um correto acoplamento eletromecânico, torna-se factível a identificação do dano.

Devido as propriedades dielétricas dos materiais piezoelétricos, o método de impedância pode usar um único componente como sensor (coletando a assinatura de admissão eletromecânica na faixa de frequência especificada) e atuador (impondo um sinal de tensão variável para produzir uma resposta dinâmica estrutural). Essa capacidade de usar um menor número de transdutores para a coleta de dados (sem perder a capacidade de identificar a presença de danos e, ao mesmo tempo, contribuir para o custo operacional) é considerada como uma das principais vantagens do método EMI. Portanto, o método de impedância se torna mais facilmente aplicável em situações complexas, quando comparado a outras técnicas clássicas de monitoramento estrutural.

A partir da equação da admitância definida por Liang, Sun e Rogers (1997b), é possível associar a deformação mecânica de uma estrutura com a variação elétrica de um transdutor PZT (acoplado a essa mesma estrutura). Dessa forma, as assinaturas de impedância eletromecânica, comumente, são descritas de acordo com as características intrínsecas e geométricas do sistema estrutura/transdutor.

Logo, considerando-se que o material piezoelétrico utilizado como sensor permaneça íntegro durante o ensaio experimental, uma representação matemática de seu modelo eletromecânico (que interligue a impedância elétrica do transdutor com a impedância mecânica da estrutura utilizada) pode ser descrita de acordo com a equação (2.7),

$$Y(\omega_e) = \frac{I_e}{V_e} = i\omega_e a \left[ \varepsilon_{33}^{-T} (1 - i\delta) - \left( \frac{Z_s(\omega_e)}{Z_s(\omega_e) - Z_a(\omega_e)} \right) d_{3x}^2 \hat{Y}_{xx}^E \right] \quad (2.7)$$

onde  $Y(\omega_e)$  representa a admitância elétrica do sistema (vista como sendo o inverso da impedância elétrica);  $\hat{Y}_{xx}^E$  é o módulo complexo de Young do adesivo PZT em um campo de tensão elétrica nulo;  $d_{3x}^2$  é a constante de acoplamento piezoelétrica numa direção  $x$  arbitrária e deformação nula;  $\delta$  é o fator de perda dielétrica tangencial à pastilha PZT;  $\varepsilon_{33}^{-T}$  é a constante dielétrica do PZT com tensão zero;  $Z_a$  é a impedância mecânica do transdutor;  $Z_s$  é a impedância mecânica da estrutura monitorada e  $a$  é a constante geométrica do adesivo PZT.

Convém destacar que a admitância elétrica apresentada é essencialmente capacitiva, onde o termo imaginário (reatância elétrica) é mais suscetível a fatores ambientais (como a variação de temperatura e ruído) do que a parte real (resistência elétrica). Logo, diversos trabalhos científicos tem privilegiado o emprego da parte real das assinaturas de impedância eletromecânica, atribuindo assim maior veracidade ao monitoramento de integridade estrutural (RAJU, 1997; BARELLA *et al.*, 2017).

Ademais, a partir da equação (2.7) pode-se observar também que as assinaturas de impedância eletromecânica estão intimamente relacionadas a frequência de excitação ( $\omega_e$ ) do sistema. Dessa forma, para se detectar a existência de alterações incipientes, o comprimento de onda utilizado deve ser suficientemente pequeno (RAJU, 1997). Portanto, faixas de alta frequência comumente são usadas para executar o método de impedância eletromecânica.

Em geral, de acordo com a literatura, a escolha da melhor faixa de frequência para monitorar a integridade estrutural é realizada por processos de tentativa e erro. No entanto, nos últimos anos, vários estudos foram realizados com o objetivo de consolidar metodologias que determinem as melhores faixas de frequência para os métodos de SHM. Essas metodologias atualmente são baseadas em processos probabilísticos e otimização (PALOMINO *et al.*, 2008; BAPTISTA; FILHO, 2010).

Em seu trabalho, MOURA JR e STEFFEN JR (2004) descrevem um método estatístico para a escolha das melhores bandas de frequência em um ensaio estrutural. Para isso, foi instrumentada uma viga de alumínio em uma bancada de testes e, posteriormente, um metamodelo foi implementado a fim de se delimitar as melhores configurações para o monitoramento de integridade estrutural por impedância eletromecânica.

Já no trabalho de Bento (2018), três métodos de otimização bioinspirada foram investigados quanto a definição da melhor faixa de frequência para o monitoramento de integridade estrutural de uma viga de alumínio retorcida. As assinaturas de impedância eletromecânica foram coletadas por meio de uma placa de aquisição de baixo custo e, subsequentemente, os três métodos de otimização (busca aleatória, colônia de abelhas e colônia de formigas) foram desenvolvidos tendo como função objetivo uma métrica de dano estrutural.

Cabe destacar ainda, que embora algumas alterações eletromecânicas de impedância possam ser facilmente observadas, é recomendável implementar um modelo matemático apropriado de tomada de decisão. Esse modelo envolve a definição de indicadores métricos que podem melhorar a capacidade de detectar danos, incorporar confiabilidade aos processos de previsão e reduzir a complexidade do problema.


Dentre os principais indicadores métricos aplicados ao método de monitoramento da integridade estrutural por impedância eletromecânica estão: as variações do desvio médio da raiz quadrada (RMSD - *Root-Mean-Square Deviation*) e o desvio do coeficiente de correlação (CCD – do inglês *Correlation Coefficient Deviation*), os quais serão melhor abordados na Seção 2.4.1.

Normalmente, em trabalhos científicos, as métricas de dano são representadas por meio de *boxplots*, que possuem a capacidade de demonstrar visualmente a separação intergrupar dos estados estruturais, através de representações não paramétricas que revelam

o grau de dispersão dos dados e a existência de *outliers*. No entanto, quando os conjuntos métricos são linearmente inseparáveis, técnicas mais robustas de abstração de dados (em especial as aplicações de *machine learning*) se tornam necessárias, propiciando a classificação dos grupos e/ou fazendo previsões a respeito. A Figura 2.6 apresenta um exemplo no qual a identificação de danos estruturais por meio da observação de *boxplots* não é trivial.

A maioria das técnicas de abstração é baseada em processos de seleção e classificação manual dos recursos de um conjunto de dados, com o objetivo principal de mapear uma relação desconhecida entre eles. Nesse contexto, as chamadas Redes Neurais Artificiais (RNAs) têm se tornado de especial interesse pelos pesquisadores nas últimas décadas, dada a sua capacidade de automatizar o processo de seleção de recursos, sendo assim aplicadas à diversos estudos para identificação da existência de danos (RHIM; LEE, 1995; BAKHARY; HAO; DEEKS, 2007; BAKHARY *et al.*, 2007; MOURA JR, 2008; LEUCAS, 2009; SELEEMAH; ABOURAYAN; SAMY, 2012; SINGHA; CHOWDARYA; MAHAPATRAA, 2017; FENG *et al.*, 2019).

Figura 2.6 – Representação gráfica da inseparabilidade linear entre grupos de métrica de dano.



Fonte: O autor (2021).

### 2.4.1 Métodos para avaliação direta do dano

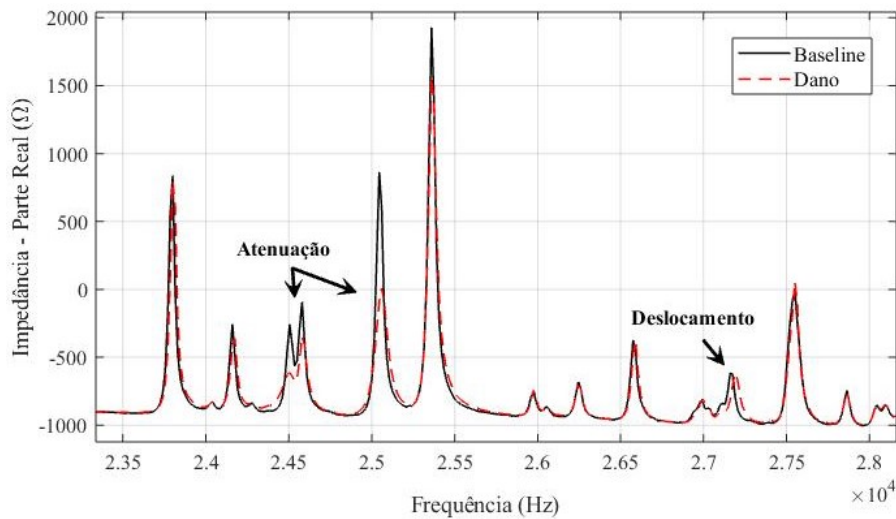
A identificação de falhas estruturais pelos métodos de SHM, de uma forma geral, envolve a comparação de dois estados fundamentais do sistema monitorado: sua condição íntegra e sua condição danificada. Para tanto, é realizada uma etapa de aquisição periódica das assinaturas de impedância eletromecânica e, posteriormente, uma verificação estatística dos sinais monitorados determina a presença de danos (SILVA *et al.*, 2017).

Uma observação direta das assinaturas de impedância nos possibilita apenas uma abordagem qualitativa de análise, a qual é dada pela visualização de deslocamentos frequênciais e/ou atenuações dos picos de ressonância (SUN *et al.*, 1997; MOURA JR, 2008). A Figura 2.7 apresenta um exemplo desses aspectos em um conjunto de assinaturas de impedância eletromecânica.

Pode-se observar na Figura 2.7 a ocorrência de alterações entre os sinais medidos. Estas alterações sugerem uma variação das condições físicas do sistema estrutural e, conseqüentemente, uma possível presença de danos. No entanto, esse tipo de análise qualitativa se restringe apenas a verificação da existência de dano, e não a mensuração propriamente dita, no nível de integridade estrutural.

Uma vez que as assinaturas de impedância eletromecânica são suscetíveis à variação de temperatura do sistema (apresentando-se no formato de deslocamentos verticais e horizontais de todos os picos de ressonância), pode-se verificar ainda na Figura 2.7 que as alterações se apresentam de forma pontual e não no deslocamento total da assinatura de impedância. Assim, o exemplo retratado demonstra essencialmente uma identificação qualitativa do dano (fazendo-se uso de apenas sinais coletados das estruturas).

Figura 2.7 – Exemplo de análise qualitativa em assinaturas de impedância eletromecânica.



Fonte: O autor (2021).

Para se obter uma análise quantitativa, o método de SHM por impedância eletromecânica comumente utiliza equações estatísticas denominadas por métricas de dano. Estas equações, quando aplicadas, resultam em um valor escalar que delimita o grau de disparidade entre o conjunto de assinaturas monitoradas durante a vida útil das estruturas em estudo e o seu padrão histórico de referência, ou seja, a assinatura de impedância no seu estado íntegro (BARELLA *et al.*, 2017; RABELO *et al.*, 2017b).

No âmbito do monitoramento de integridade estrutural, a métrica de dano mais comumente utilizada em trabalhos científicos é chamada de desvio médio da raiz quadrada (RMSD – do inglês *Root-Mean-Square Deviation*), sendo essa expressa conforme a equação (2.8),

$$RMSD_j = \sqrt{\sum_{i=1}^n \left( \frac{(Re(Z_{b,i}) - Re(Z_{j,i}))^2}{n} \right)} \quad (2.8)$$

onde  $Re(Z_{b,i})$  representa a parte real da assinatura de *baseline* (sinal de referência da estrutura) em uma frequência de excitação  $i$ ,  $Re(Z_{j,i})$  é parte real da assinatura de impedância para uma nova configuração  $j$  da estrutura (nesta mesma frequência de excitação  $i$ ) e  $n$  é o número de pontos frequências das assinaturas utilizadas.

Para cálculo da métrica, deve-se verificar que o domínio frequencial empregado é essencialmente discreto, sendo este previamente delimitado no procedimento experimental. Outras abordagens da métrica de dano RMSD são dadas em (RAJU, 1997; PARK; INMAN, 2001; TSENG; NAIDU, 2002; NAIDU; SOH, 2004; GIURGIUTIU; ZAGRAI, 2005); dentre elas à que realiza a substituição entre: o denominador ( $n$ ) e o quadrado do sinal de referência da estrutura (PARK; INMAN, 2001; MOURA JR, 2008), conforme é apresentado na equação (2.9),

$$RMSD_j = \sqrt{\sum_{i=1}^n \left( \frac{(Re(Z_{b,i}) - Re(Z_{j,i}))^2}{Re(Z_{b,i})^2} \right)} \quad (2.9)$$

A substituição exibida na equação (2.9) não altera significativamente o resultado da métrica de dano dada pela equação (2.8). Todavia, esta passa a considerar uma proporcionalidade maior em relação ao número individual de pontos frequenciais.

Outro índice métrico também amplamente utilizado na literatura é denominado por desvio do coeficiente de correlação (CCD – do inglês *Correlation Coefficient Deviation*). Esse índice é usado para quantificar um grau de similaridade entre dois conjuntos de pontos amostrais, que no caso em questão é dado pelas assinaturas de impedância eletromecânica (GIURGIUTIU; ZAGRAI, 2005).

Sua formulação matemática envolve a diferença entre um valor ótimo (1 – índice de correspondência máxima) e o coeficiente de correlação dos grupos amostrais (assinatura de *baseline* e medição avaliada). Deste modo, o índice CCD pode ser expresso conforme a equação (2.10),

$$CCD_j = 1 - \left( \frac{1}{n} \left( \sum_{i=1}^n \frac{(Re(Z_{b,i}) - Re(\bar{Z}_{b,i})) * (Re(Z_{j,i}) - Re(\bar{Z}_{j,i}))}{S_{Z_b} * S_{Z_j}} \right) \right) \quad (2.10)$$

onde  $\bar{Z}_{b,i}$  e  $\bar{Z}_{j,i}$  são as médias das partes reais da impedância medida para as condições de *baseline* e de teste, respectivamente;  $S_{Z_b}$  é o desvio padrão da assinatura de *baseline* e  $S_{Z_j}$  é o desvio padrão do sinal avaliado.

Ressalta-se que a métrica de dano baseada no coeficiente de correlação foi extensivamente investigada por Koo *et al.* (2009) e Rabelo *et al.* (2017a), sendo utilizada principalmente em algoritmos de compensação de temperatura. Quando o desvio do coeficiente de correlação é mais próximo de 0, significa que os sinais mensurados possuem uma melhor correspondência, possibilitando assim o emprego do índice como métrica a ser otimizada.

Tal idealização também pode ser verificada em [Park et al. \(1999\)](#) e [Bento et al. \(2017\)](#) para a métrica de dano RMSD.

No entanto, deve-se observar que a representação dos sinais de monitoramento por um único índice métrico, introduz a necessidade da função escolhida ser bijetora em todo o espaço de análise, isto é, deve-se garantir que apenas uma única combinação de diferenciabilidade entre os sinais medidos forneça o valor observado pela métrica de danos. Porém, tal condicionamento não é verificado no método de impedância, uma vez que dois sinais, não necessariamente semelhantes, podem resultar em um mesmo valor métrico. Assim, métodos de avaliação que permitem o uso de uma maior quantidade de informações das assinaturas de impedância, como as técnicas de *machine learning*, podem ser utilizados para garantir resultados mais confiáveis.

## 2.5 Sistemas de Aquisição para Coleta das Assinaturas de Impedância Eletromecânica

Conforme descrito na Seção 2.4, as assinaturas de impedância eletromecânica são obtidas a partir de sinais de sensores, geralmente piezoelétricos, que são acoplados ou inseridos a uma estrutura hospedeira. Esses transdutores, por sua vez, são conectados a um sistema de aquisição, no qual os dados são transmitidos, fisicamente por meio de uma conexão a cabo ou via *Wi-Fi*, à uma unidade de processamento, seja ela um computador ou um servidor remoto.

Nesse sentido, os analisadores de impedância têm forte influência na aplicabilidade do monitoramento de integridade estrutural, uma vez que, além de caros (atingindo valores de até 30mil dólares), alguns equipamentos podem ser pesados o suficiente para inviabilizar a aplicação da técnica ([TEBALDI, 2004](#); [BENTO, 2018](#)). Um exemplo desse condicionamento pode ser visto no monitoramento de estruturas de difícil acesso, onde fontes externas de energia e fiação para conexões não são usuais ou até mesmo inexistentes.

Alguns trabalhos científicos, dessa forma, têm buscado novas alternativas de sistemas de aquisição em que tanto o custo do equipamento quanto sua disponibilidade de acoplamento em estruturas de difícil acesso e sua capacidade de integração remota com a estrutura de avaliação são levados em consideração ([TEBALDI, 2004](#); [BARELLA et al., 2017](#)). Assim, nas seções posteriores, são listados alguns dos principais sistemas de aquisição usados para se monitorar a integridade estrutural de sistemas mecânicos pelo método de impedância eletromecânica.

### 2.5.1 Modelos *HP*

Os modelos *HP*, embora desatualizados, são exemplos de analisadores de impedância que ainda são amplamente utilizados em trabalhos científicos da atualidade ([AFSHARI,](#)

2012). Esses analisadores têm até onze funções de medição de impedância e cobrem uma faixa de frequência de  $100\text{Hz}$  a  $40\text{MHz}$  para se monitorar a integridade estrutural (PALOMINO *et al.*, 2008). A Figura 2.8 mostra um exemplo de um analisador de impedância da marca HP.

Além disso, os níveis de saída do equipamento são de  $10\text{mV}$  a  $1\text{Vrms}$  e suas configurações de experimentação ajustáveis ao tipo de problema a ser tratado, possibilitando assim uma ampla gama de aplicações reais. No entanto, como desvantagem desse tipo de equipamento pode-se citar o seu alto custo e sua robustez, não sendo portátil e nem aplicável ao monitoramento de estruturas remotas.

Por outro lado, sua instrumentação em laboratório apresenta grande aplicabilidade, possibilitando a aquisição de um grande volume de dados em estruturas complexas com alta precisão. Gruppioni, Moura Jr e Rade (2006) utilizaram o modelo de analisador de impedância HP4194A para monitorar estruturas do tipo viga de alumínio engastada-livre, quanto ao seu estado de integridade estrutural. Para isso, fissuras nas laterais das vigas foram introduzidas em uma etapa do experimento. As assinaturas de impedância coletadas mostram a capacidade e precisão do sistema de monitoramento usado.

Figura 2.8 – Sistema de Aquisição de Assinaturas de Impedância - Modelo HP 4194A.



Fonte: Retirado de Gruppioni, Moura Jr e Rade (2006).

Já no trabalho de Tsuruta (2008), o mesmo sistema de aquisição foi usado para monitorar danos por impacto de baixa energia em placas laminadas de fibra de carbono. Para tanto, uma estrutura pendular foi desenvolvida e aplicada a fim de gerar uma variedade de condições de integridade das estruturas hospedeiras. Resultados de metamodelos desenvolvidos na metodologia evidenciam a capacidade do método de impedância eletromecânica quanto ao monitoramento de integridade estrutural.


## 2.5.2 Modelos baseados no Circuito Integrado (CI) AD5933

Uma alternativa de baixo custo para os sistemas de aquisição de assinatura de impedância são aqueles baseados no CI AD5933, que fornece ao usuário uma aquisição programada dos sinais de impedância eletromecânica. Desta forma, as definições do microcontrolador e do gerador de frequência podem ser configuradas, de modo a considerar as melhores características para a inspeção das estruturas em estudo.

Entre os principais sistemas de aquisição que utilizam o CI AD5933 estão: o conversor PmodIA (da empresa *Diligent*) e a placa EVAL AD5933EBZ (da empresa *Analog Devices*) (BARELLA *et al.*, 2017; BENTO, 2018). Tais sistemas de aquisição têm se mostrado de grande utilidade no monitoramento de estruturas metálicas, apresentando resultados satisfatórios no contexto de SHM através de sistemas de baixo custo.

A aquisição dos sinais pela placa Eval AD5933EBZ (Figura 2.9) é amostrada pelo conversor analógico digital e um microcontrolador processa e realiza a transformada discreta de *Fourier* (DFT) nos mesmos. A placa opera com uma tensão de alimentação de 2.7V a 5.5V, que normalmente é fornecida por meio de uma porta USB no computador. Essa porta, por sua vez, permite registrar a magnitude e a fase da impedância, pelas quais é calculada a parte real da impedância eletromecânica (SEPEHRY; SHAMSHIRSAZ; BASTANI, 2011; DEVICES, 2020).


Figura 2.9 – Placa de aquisição de dados EVAL AD5933EBZ.



Fonte: Retirado de DEVICES (2020).

A placa PmodIA, por outro lado, garante uma configuração mais autônoma para o usuário, permitindo que um maior número de parâmetros do processo de aquisição seja definido ao sistema, reprogramando-o de acordo com as características do experimento. Para tanto, um conversor analógico digital (ADC) é utilizado pelo sistema para excitar uma impedância externa desconhecida em uma frequência de excitação conhecida. Tal frequência de excitação é enviada para a estrutura em estudo, através de um dos conectores SMA e a resposta correspondente é captada pelo outro conector SMA. Posteriormente o conversor ADC realiza a transformada discreta de *Fourier* para armazenamento das partes reais e imaginárias da solução (i.e, da assinatura de impedância) (DIGILENT, 2020). A Figura 2.10 apresenta um módulo PmodIA.

Figura 2.10 – Conversor PmodIA.



Fonte: Retirado de [DIGILENT \(2020\)](#).

O componente eletrônico mostrado na Figura 2.10 tem um custo de aproximadamente \$39, representando uma redução de custo considerável em comparação com outros modelos de analisadores de impedância no mercado. Além disso, deve-se considerar que o componente pode ser integrado a outros módulos do Arduino, possibilitando também a integração via porta serial I2C com outras linguagens de programação, como *Python*.

## Capítulo 3

---

# Caracterização Básica das Redes Neurais Artificiais

---

Este capítulo é dedicado à apresentação de alguns conceitos fundamentais sobre redes neurais artificiais, incluindo o contexto de aprendizado de máquina, aprendizado profundo e inteligência artificial usados nas formulações das RNAs.

A origem das redes neurais também é brevemente descrita, englobando sua idealização e componentes básicos: como funções de ativação, formas de aprendizado e avaliação de modelos neurais e o processo de treinamento mais utilizado no contexto do trabalho proposto.

### 3.1 Conceitos de *Machine Learning* e *Deep Learning*

Com o aperfeiçoamento dos sistemas de aquisição e armazenamento de dados, ao longo dos anos, o volume de informações coletadas se expandiu consideravelmente (KOMAL, 2018; BHARTI; VERMA; DEEPAK, 2019). Essa ampliação na quantidade de dados disponíveis, no entanto, acaba dificultando a execução manual de tarefas de abstração, o que, aliado ao recente desenvolvimento tecnológico, incentivou a elaboração de ferramentas automatizadas de análise, cujas quais constituem hoje o chamado aprendizado de máquina.

A aprendizagem de máquina (ML – do inglês *Machine Learning*) pode ser definida como uma subárea da Inteligência Artificial, voltada para o desenvolvimento de técnicas e/ou algoritmos computacionais, capazes de realizarem a extração de características nos mais variados tipos de problema da atualidade (PROVOST; KOHAVI, 1998).

Em geral, os algoritmos de *machine learning* se baseiam na criação de um modelo de inferência programável, em que, a partir de dados amostrais, uma resposta de previsão é obtida (MULLAINATHAN; SPIESS, 2017). Deste modo, tais algoritmos consistem em encontrar, automaticamente, representações mais úteis dos dados, mapeando uma relação desconhe-

cida dos mesmos em um espaço de hipóteses.

O processo de aprendizado em ML é executado de forma indutiva, onde padrões de respostas são definidos automaticamente, através de experiências já observadas pelo modelo matemático (PROVOST; KOHAVI, 1998). Deste modo, tem-se como principal desafio a formulação de problemas irregulares, nos quais uma lista de regras matemáticas não é facilmente mensurável.

Algumas concepções de IA, antes empregadas na resolução de problemas complexos, se baseavam em características especificadas por operadores humanos, os quais eram também responsáveis por delimitarem todo tipo de conhecimento utilizado pelo computador. Entretanto, uma limitação desse tipo de abordagem é a dificuldade em determinar que tipos de características se fazem necessárias para o processo de abstração (LIANG; GUIXI; HONGYAN, 2015).

As técnicas de *machine learning*, por outro lado, visam extinguir a necessidade de se definir formalmente quais características o classificador deve usar, através de uma representação hierárquica de conceitos (ABU-MOSTAFA; MAGDON-ISMAIL; LIN, 2012). Assim, o conhecimento é obtido por experiência, possibilitando que o computador faça previsões e/ou classificações de conceitos complexos, por meio da abstração de conceitos mais simples (SALAKHUTDINOV, 2015).

Nesse sentido, as redes neurais artificiais (RNAs) têm se destacado como uma das principais técnicas de *machine learning*, contribuindo ao mesmo tempo para o desenvolvimento de diversas áreas do conhecimento (MENEZES *et al.*, 2009; BARROS; MORAIS; FERNANDES, 2017; GULGEC; TAKÁČ; PAKZAD, 2017; MHATRE *et al.*, 2017; SHARMA; SINGH, 2017; COFRE-MARTEL *et al.*, 2019). Sua eficiência se dá principalmente pelo modo como o processamento de dados é executado, em que as operações aplicadas se aproximam particularmente daquelas realizadas pelo cérebro humano.

Enquanto que as demais abordagens de *machine learning* utilizam uma série de blocos lógicos para a execução do processo de aprendizado, as RNAs operam sobre uma rede paralela de nós (MHATRE *et al.*, 2017). Estes nós, são responsáveis por processar localmente as informações abstraídas e, posteriormente, por meio de um algoritmo de treinamento, suas saídas de resposta são otimizadas para obter a melhor resolução do problema observado.

Deve-se notar que nenhuma arquitetura neural é igualmente aplicável a todos os tipos de problemas encontrados na literatura. Desse modo, vários tipos de RNAs foram desenvolvidas ao longo do tempo (HOPFIELD, 1984; KOHONEN, 1990; MOURA JR, 2008; GOODFELLOW; BENGIO; COURVILLE, 2016; SUPRATAK *et al.*, 2017).

A maioria das arquiteturas neurais são compostas por uma série de unidades de processamento (denominadas por neurônios artificiais), que são distribuídas em grupos (de-

nominados por camadas) na forma de cadeia (MHATRE *et al.*, 2017). Assim, cada camada neural é uma função combinada da camada antecessora e, portanto, a assertividade de uma RNA é dependente, também, do número de camadas utilizadas.


Quando uma RNA é composta de três ou mais camadas de processamento, essa é caracterizada como uma rede neural profunda, e a sua aplicação compõe o chamado aprendizado profundo (DL - do termo em inglês *Deep Learning*) (YU *et al.*, 2015; BLANCO *et al.*, 2019).

Na abordagem de *deep learning*, os níveis de representação dos dados utilizados obedecem a um fluxo hierárquico, isto é, as características de alto nível são obtidas exclusivamente através da composição de níveis inferiores, que se especializam em um determinado tipo de informação (MASSUCATTO, 2018; MOHSEN *et al.*, 2018).

Para isso, os modelos de aprendizagem profunda, usualmente, requerem grandes volumes de dados e uma quantidade elevada de camadas ocultas para abstração (MASSUCATTO, 2018; MOHSEN *et al.*, 2018). Em consequência, um alto custo computacional também é exigido, com o processamento de dados sendo frequentemente executado na unidade gráfica do computador (YU *et al.*, 2015).

Convém observar ainda, que o tema *deep learning* é uma vertente do aprendizado de máquina (Figura 3.1), que têm conquistado grande importância nos últimos anos, principalmente devido à sua capacidade de resolver problemas que até então não eram tratáveis; sendo um deles o monitoramento de integridade estrutural (GULGEC; TAKÁČ; PAKZAD, 2017; BLANCO *et al.*, 2019).

Figura 3.1 – Associação entre os temas de Inteligência Artificial, *Machine Learning* e *Deep Learning*.



Fonte: O autor (2021).

O objetivo de usar um número maior de camadas nos modelos neurais é aumentar a abstração dos dados, que são avaliados sob diferentes perspectivas, a fim de melhor condensar e associar as relações entre as entradas e as saídas do modelo (GULGEC; TAKÁČ; PAKZAD, 2019).

## 3.2 Tarefas realizadas em *Deep Learning*

Conforme apontado na Seção 3.1, algoritmos de *machine learning* foram desenvolvidos para suprir e lidar com problemas complexos, que a princípio são impossíveis de serem solucionados por algoritmos sequenciais ou métodos manuais. Desta forma, do ponto de vista científico, os benefícios do aprendizado de máquina se tornam notáveis, dada sua capacidade de elucidar variados tipos de tarefas através de conceitos mais básicos nos quais se baseia a inteligência (HAYKIN, 2007).

No contexto de *deep learning*, as tarefas realizadas por um modelo neural vão ainda mais longe, sendo descritas em termos de como esse modelo deve processar as instâncias adquiridas para seu treinamento e validação (GOODFELLOW; BENGIO; COURVILLE, 2016). Tais tarefas podem ainda ser comumente qualificadas como atos de predição ou inferência de dados, os quais são avaliados como uma coleção de recursos (*features*), adquiridos de forma vetorial ou matricial, em que cada vetor representa apenas um único estado observado, ou seja, uma amostra (GOODFELLOW; BENGIO; COURVILLE, 2016). Em DL, dentre as principais tarefas comumente empregadas, pode-se citar:

- ✓ **Classificação** - em que um modelo (de treinamento geralmente supervisionado) é solicitado a identificar a qual das categorias  $k$  pertence uma determinada instância  $x$  de dados. Para isso, o modelo é baseado na produção de uma função de mapeamento  $f(x)$ , que descreve uma relação unívoca dos dados observados em um espaço de hipótese  $y$ . A classificação de um conjunto de dados pode ser considerada uma tarefa de inferência, que possui diversos aspectos de avaliação como a classificação binária, a classificação multiclasse, a classificação com entradas ausentes, entre outros.
- ✓ **Regressão** - que ao contrário dos processos de classificação, apresenta um sentido de dependência, ou seja, a relação observada é dada como uma correlação entre os dados de entrada  $x$  e uma saída  $y$  do modelo (geralmente obtida no espaço  $\mathbb{R}$ ). Tal correlação também é dada por uma função de mapeamento  $f(x) \rightarrow y$ , porém, como resultado disso, um valor de predição é obtido e não uma classe ou rótulo de inferência.
- ✓ **Detecção de Anomalias** - na qual um conjunto de eventos é avaliado para que correlações entre as variáveis (*features*) do conjunto de dados sejam detectadas e combinadas, de forma que variações nessas combinações indiquem a presença de atributos atípicos e/ou anômalos. Essas correlações são usadas para criar um espaço de recursos mais compacto e claro para identificar as diferentes variações dos dados. Para este propósito, ferramentas de extração de recursos são comumente utilizadas em suporte ao modelo neural, como o PCA ou  $k$ -means.

No presente trabalho, todas as tarefas acima mencionadas serão de certa forma aplicadas ao contexto do SHM por impedância eletromecânica por meio de modelos neurais convolucionais e/ou LSTM.

### 3.3 Conceito Geral de Redes Neurais Artificiais

As RNAs são modelos computacionais, inspirados nos princípios da estrutura e do fluxo de transmissão nervosa entre neurônios biológicos, que têm a capacidade de aprender através da observação repetida de dados históricos (GOODFELLOW; BENGIO; COURVILLE, 2016; JIANG *et al.*, 2017). No entanto, tais modelos computacionais são bem mais simplificados e restritos, se comparados a real arquitetura do sistema nervoso humano (MURPHY; KAIRISS, 1995; BARRETT; MORCOS; MACKE, 2019).


Enquanto que o sistema neural biológico pode ser constituído por até bilhões de células nervosas, sendo que cada uma dessas células possui uma complexidade funcional bem mais elevada, a capacidade de processamento de uma RNA é limitada, visto que a sua modelagem dispõe de dezenas a no máximo milhares de unidades de processamento (JIANG *et al.*, 2017).

O primeiro e mais aceito modelo de neurônio artificial que se tem história, é aquele apresentado no artigo de Warren McCulloch e Walter Pitts de 1943. Os quais descreveram o neurônio artificial como sendo um dispositivo binário, a fim de utilizá-lo para a resolução dos mais variados problemas de circuitos elétricos (MCCULLOCH; PITTS, 1943; JIANG *et al.*, 2017).

O modelo *MP Neuron* ou Discriminador Linear, conforme assim denominado por McCulloch e Pitts na época, realiza em termos simples a agregação de todas as entradas binárias de dados e, a partir do resultado dessa agregação, uma certa decisão é tomada através de uma função de transferência (MOURA JR, 2008).

A saída do neurônio artificial é resultante da ativação ou não ativação da função de transferência, a qual é controlada por um valor de limiar ( $\delta$ ) pré-estabelecido (HAYKIN, 2007). A Figura 3.2 apresenta uma esquematização do modelo neural de Warren McCulloch e Walter Pitts de 1943.

Figura 3.2 – Representação gráfica do modelo *MP Neuron*.




Fonte: O autor (2021).

Percebe-se pela Figura 3.2 que o processo de agregação presente no modelo *MP Neuron* consiste basicamente no somatório de todas as entradas ( $x_i$ ) de dados, assemelhando-se ao que se ocorre dentro do corpo celular de um neurônio biológico (MOURA JR, 2008; FA-

RIA, 2018). Quando essa soma atinge um limite superior, o neurônio artificial alcança seu estado de saturação, respondendo conforme a sua função de ativação ( $\varphi$ ).

No modelo de McCulloch e Pitts, a função de ativação usada é do tipo degrau unitário, que pode ser expressa de acordo com a Figura 3.3 (HAYKIN, 2007). Nessa função, a ocorrência de um pulso retornará o valor 1 e a sua não ocorrência o valor 0, justificando assim o emprego de tal modelo na abstração de componentes elétricos.

Figura 3.3 – Função de ativação do neurônio artificial de McCulloch e Pitts.



Fonte: O autor (2021).


Posteriormente, em resposta à idealização do modelo de McCulloch e Pitts, diversas outras formas de modelagem do neurônio artificial foram amplamente investigadas e, dentre as principais, destaca-se o modelo de rede chamado *Perceptron*. Esse, foi inicialmente descrito e formulado pelo neurofisiologista Frank Rosenblatt em 1958 (ROSENBLATT, 1958).

O *Perceptron* foi o primeiro tipo de RNA estruturada, isto é, organizada na forma de camada. Tal arquitetura causou um grande impacto na comunidade científica, sendo considerada como o aperfeiçoamento do modelo *MP Neuron* (ROSENBLATT, 1958). O modelo de Rosenblatt acrescentou diversos componentes à estrutura básica do neurônio artificial, possibilitando assim um processo de aprendizado mais próximo ao do sistema neural biológico.

As unidades de processamento contidas no modelo *Perceptron* são denominadas por *Linear Threshold Unit* (LTU) e possuem as mesmas funcionalidades básicas do modelo *MP Neuron*. No entanto, nestas são acrescentados pesos de ponderação ( $w_i$ ) em cada uma das conexões de entrada da rede, além de ser adicionado um dado valor escalar ( $b$ ) de ajuste, conhecido por *bias* (HAYKIN, 2007). A Figura 3.4 apresenta o modelo gráfico da rede *Perceptron*, desenvolvida por Frank Rosenblatt em 1958.

Em geral, as etapas de agregação e verificação dentro do neurônio artificial permanecem as mesmas. No entanto, os valores de ponderação ( $w_i$ ) e *bias* ( $b$ ) são adicionados ao modelo, de acordo com a equação (3.1),

$$y_i = \varphi \left( \sum_{i=1}^n (x_i w_i + b) \right) \quad (3.1)$$

Figura 3.4 – Representação gráfica do modelo *Perceptron*.

Fonte: O autor (2021).

O valor de *bias* deve ser definido de modo a ajustar a resposta da função de transferência, tornando os resultados de saída mais próximos ao do esperado. Já os pesos de ponderação, também conhecidos como pesos sinápticos, são inicializados de forma aleatória, sendo posteriormente atualizados ao decorrer do processo de treinamento da rede neural.

Deve-se verificar que a forma de treinamento do modelo *Perceptron* é do tipo supervisionada, isto é, as classes de saída das amostras de treinamento já são previamente especificadas e o conceito de aprendizado em si, consiste apenas no ajuste dos pesos de ponderação da rede (FARIA, 2018). Desse modo, o processo de treinamento do modelo *Perceptron* é orientado essencialmente para frente (*feedforward*), no qual cada amostra de treinamento é passada uma única vez por todo escopo da rede.

A adição de novos componentes à estrutura básica do neurônio artificial, bem como o desenvolvimento de um processo de treinamento de rede neural, possibilitou ao *Perceptron* a capacidade de trabalhar não apenas com os valores binários, mas também com os valores reais e bipolares (-1 ou 1) (HAYKIN, 2007). No entanto, como grande limitação, ainda persistente a esse tipo de rede, pode-se citar o fato dela não conseguir diferenciar distintos conjuntos de amostras não-lineares. Problema este, que foi abordado em 1969 no livro “*Perceptrons – An Introduction to Computation Geometry*”, dos autores Marvin Minsky e Seymour Papert (SEGATTO; COURY, 2006; MINSKY; PAPERT, 2017).

No livro, Minsky e Papert descrevem a impossibilidade de implementação da porta lógica XOR por meio do uso exclusivo de redes neurais de camada única. Assim, após um curto período de expansão das RNAs e com a publicação do livro de Minsky e Papert, houve um grande período de estagnação nas pesquisas de rede neurais artificiais (HOPFIELD, 1982; SEGATTO; COURY, 2006). Tal acontecimento se deve, principalmente, ao fato dos algoritmos de treinamento e aprendizado da época não possibilitarem o acoplamento de mais de uma camada de processamento.

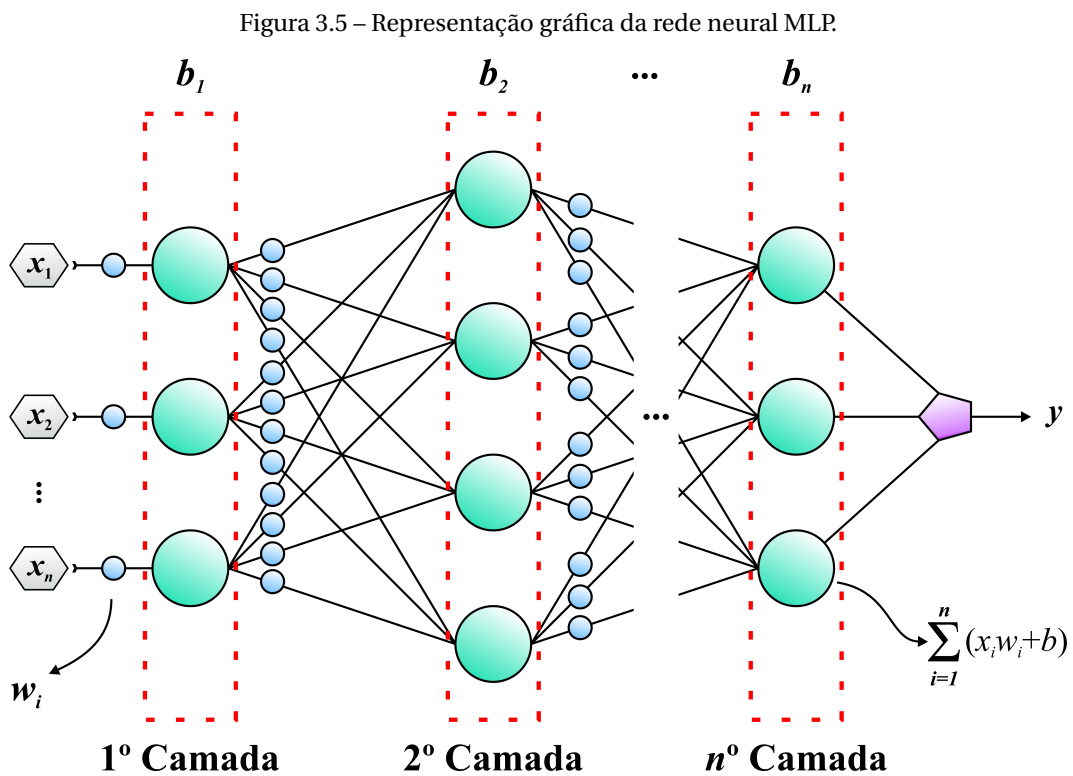
A fase de estagnação das pesquisas de RNAs somente foi superada 15 anos após, com as publicações do físico-matemático John Hopfield (HOPFIELD, 1982; HOPFIELD, 1984).

As redes de Hopfield acrescentaram novos ideais à modelagem das redes neurais artificiais, possibilitando assim o acoplamento de outras camadas de processamento.

Convém verificar, que nessa mesma época, outras formulações matemáticas também passaram a ser introduzidas nos estudos de *machine learning*, como por exemplo: a convolução, a normalização e os estados transientes (FUKUSHIMA, 1975; KOHONEN, 1990; SAINATH *et al.*, 2015). Estas formulações, apoiadas ao avanço tecnológico, deram origem a novas vertentes de RNAs, que posteriormente levaram ao desenvolvimento das atuais redes neurais convolucionais, redes recorrentes e outros tipos de arquitetura profunda (HOCHREITER; SCHMIDHUBER, 1997; LIU; LEE; TARNG, 2000).

No entanto, deve-se ressaltar que o grande impulso no campo das RNAs se deu apenas com o desenvolvimento de novos algoritmos de treinamento mais eficientes, em especial o *backpropagation* (RUMELHART; HINTON; WILLIAMS, 1986). Tais algoritmos de treinamento, possibilitaram não apenas o acoplamento e ajustes dos pesos sinápticos em redes multiníveis, mas também o desenvolvimento de novas arquiteturas neuronais.

A rede *Multilayer Perceptron* (MLP), conhecida como o aperfeiçoamento do modelo *Perceptron*, foi a primeira arquitetura neural a ser generalizada para  $n$  camadas de neurônios. Esta é formada, essencialmente, por várias unidades menores de processamento, do tipo *Perceptron*, as quais são distribuídas em paralelo na forma de rede. A Figura 3.5 apresenta um exemplo da arquitetura MLP.



Fonte: O autor (2021).

A possibilidade de acoplar várias unidades de processamento em um único sistema

complexo, demonstrada pelo modelo de rede *Multilayer Perceptron*, incentivou vários estudos e avanços sobre as RNAs (HAYKIN, 2007). Como consequência, novas teorias foram criadas aplicando certas formulações que permitiram o desenvolvimento de outras áreas de uso, como a visão computacional e o tratamento de linguagem natural (BENGIO; LECUN *et al.*, 2007).

Hoje, pode-se adotar uma infinidade de topologias neurais, aplicar métodos de treinamento especiais, utilizar variadas funções de ativação e também acoplar outros mecanismos de inteligência ou memória às redes neurais artificiais (GOODFELLOW; BENGIO; COURVILLE, 2016; FENG *et al.*, 2019).

As RNAs são estruturas flexíveis, possibilitando assim a sua utilização em diversas aplicações industriais e acadêmicas (SALAKHUTDINOV, 2015). Essa flexibilidade proporciona às redes neurais artificiais a capacidade de investigarem diversas hipóteses simultaneamente, tornando-as um recurso de grande valia (MOURA JR, 2008).

As formas de implementação das RNAs são caracterizadas por serem diversificadas, sendo dependentes principalmente do tipo de topologia, do tipo de neurônio artificial (geralmente dado como uma personalização do modelo *Perceptron*) e das regras de treinamento ou aprendizado utilizadas (RUMELHART; HINTON; WILLIAMS, 1986; FENG *et al.*, 2019).

No entanto, a sua possibilidade de abstração por meio de tensores geométricos facilitou amplamente a sua manipulação, tornando o seu processo de desenvolvimento mais otimizado e simplificado. Ainda, com a atual expansão tecnológica, as RNAs vêm sendo cada vez mais utilizadas, visto que a capacidade de manipulação e de tratamento de grandes volumes de dados (estruturados e não estruturados) se tornou bem mais rápida e acessível.

### 3.3.1 Funções de Ativação

A função de ativação de um neurônio artificial é basicamente uma transformação do somatório de todas as entradas de dados (NWANKPA *et al.*, 2018), as quais são ponderadas pelos valores dos pesos sinápticos e podem ser provenientes de outros neurônios ou da própria entrada da rede neural.

Ao se utilizar funções de ativação puramente lineares, o processamento da informação se reduz à um problema de regressão linear. Porém, ainda que tais equacionamentos sejam restritos às suas características particulares, os mesmos são, em sua maioria, de resoluções simples, não necessitando assim à aplicação de técnicas de modelagem neural (HAYKIN, 2007).

Por outro lado, quando funções não lineares são usadas, uma grande variedade de tarefas complexas pode ser resolvida, por meio da aplicação das RNAs. (HAYKIN, 2007). Funções de ativação não lineares caracterizam-se por serem robustas e difíceis de modelar,

uma vez que para os processos comuns de treinamento de rede neural se faz necessário o uso do gradiente da função de ativação (MANAVAZHAHAN, 2017; NWANKPA *et al.*, 2018).

O resultado da ativação ou não ativação do neurônio artificial é propagado para as entradas de outros neurônios ou para a própria saída da rede neural (HAYKIN, 2007; NWANKPA *et al.*, 2018). Dentre as principais funções de ativação encontradas na literatura, pode-se citar: a função Degrau Unitário, a função Degrau Bipolar, a função Linear, a função *Sigmoidal*, a função Tangente Hiperbólica (*TanH*), a função *Softmax*, a Unidade Linear Retificada (*ReLU*), a Unidade Linear Exponencial (*ELU*) e a Unidade Linear com Vazamento (*Leaky ReLu*) (MHASKAR; MICHELLI, 1994; MOURA JR, 2008; GLOTOT; BENGIO, 2010; GOOD-FELLOW; BENGIO; COURVILLE, 2016; MANAVAZHAHAN, 2017; WANG *et al.*, 2020).

Todas as funções supracitadas bem como suas respectivas derivadas de primeira ordem são apresentadas no Quadro 3.1, onde  $u = \sum_{i=1}^n (x_i w_i + b)$  e  $\delta$  é o valor do limiar de ativação.

	Nome da Função	$\varphi(u)$	$\varphi'(u)$
<b>Linear</b>	Degrau Unitário	$\varphi(u) = \begin{cases} 1, & \text{se } u \geq \delta \\ 0, & \text{se } u < \delta \end{cases}$	$\varphi'(u) = 0$
	Degrau Bipolar	$\varphi(u) = \begin{cases} 1, & \text{se } u \geq \delta \\ -1, & \text{se } u < \delta \end{cases}$	$\varphi'(u) = 0$
	Linear	$\varphi(u) = au$	$\varphi'(u) = a$
<b>Não Linear</b>	<i>Sigmoidal</i>	$\varphi(u) = \frac{1}{1+e^{-u}}$	$\varphi'(u) = \varphi(u)(1 - \varphi(u))$
	<i>TanH</i>	$\varphi(u) = \frac{2}{1+e^{-u}}(2u) - 1$	$\varphi'(u) = 1 - \tanh^2(u)$
	<i>Softmax</i>	$\varphi(u) = \frac{e^u}{\sum_{k=1}^n e^{u_k}}$	$\varphi'(u) = \begin{cases} \varphi_i(1 - \varphi_k), & \text{se } i = k \\ -\varphi_i\varphi_k, & \text{se } i \neq k \end{cases}$
	<i>ReLU</i>	$\varphi(u) = \max\{0, u\}$	$\varphi'(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases}$
	<i>ELU</i>	$\varphi(u, \alpha) = \begin{cases} u, & \text{se } u \geq 0 \\ \alpha(e^u - 1), & \text{se } u < 0 \end{cases}$	$\varphi'(u, \alpha) = \begin{cases} 1, & \text{se } u \geq 0 \\ \varphi(u, \alpha) + \alpha, & \text{se } u < 0 \end{cases}$
	<i>Leaky ReLu</i>	$\varphi(u, \alpha) = \max\{\alpha u, u\}$	$\varphi'(u, \alpha) = \begin{cases} 1, & \text{se } u \geq 0 \\ \alpha, & \text{se } u < 0 \end{cases}$

Fonte: O autor (2021).

Quadro 3.1 – Principais funções de ativação utilizadas em redes neurais artificiais.

Deve-se ressaltar que, por sua simplicidade, as funções pertencentes ao grupo linear possibilitam apenas o desenvolvimento de classificadores binários, onde valores iguais ou superiores ao limiar de ativação são pertencentes a uma determinada classe neural. Já os valores inferiores a esse mesmo limiar de ativação constituem-se como uma outra classe do conjunto de dados amostrados (HAYKIN, 2007; MOURA JR, 2008).

Ainda, destaca-se que as derivadas características desses tipos de funções inviabilizam à aplicação dos métodos de retropropagação de erros, tornando os processos de treinamento e aprendizagem da rede neural bem mais limitados (NWANKPA *et al.*, 2018).

Já as funções de ativação não lineares, embora possuam uma complexidade de modelagem muito superior às funções do tipo linear, possibilitam a abstração e a resolução de problemas irregulares, nos quais as soluções encontradas nem sempre são bem-comportadas (AGOSTINELLI *et al.*, 2014; DING; QIAN; ZHOU, 2018). No cotidiano industrial é comum a existência de problemas não lineares, motivo este que justifica a predominância do uso de funções não lineares na construção de arquiteturas neurais (DING; QIAN; ZHOU, 2018).

Ademais, diferentemente do que se ocorre com as funções lineares, nos métodos de retropropagação do erro, o gradiente das funções de ativação não lineares contribui para o treinamento da rede neural. Desta maneira, mesmo que de forma complexa, as derivadas permitem que esse processo seja otimizado e eficiente (NWANKPA *et al.*, 2018).

A priori, deve-se notar que não existe uma regra conceitual que especifique qual função de ativação deve ser utilizada para compor um neurônio artificial (GLOROT; BENGIO, 2010). No entanto, Wang *et al.* (2020) demonstram em seu trabalho, que tal escolha contribui para a eficiência do modelo neural, permitindo minimizar erros de treinamento e assegurando, ao mesmo tempo, uma melhor de generalização dos dados. Ainda, a necessidade da taxa de convergência e a complexidade da arquitetura utilizada são descritas como sendo pontos importantes a serem considerados (WANG *et al.*, 2020).

Da mesma forma, Mhaskar e Micchelli (1994) desenvolveram um modelo matemático que delimita o número mínimo de neurônios para que uma rede possa abstrair informações com um certo nível de precisão. Para isso, foi considerada a influência das funções de ativação no resultado da rede, sendo medido níveis de suavização e modificação das funções *Sigmoidais*. Ambos verificaram que tais características também influenciam a precisão do modelo neural, sendo assim necessário uma maior cautela no emprego deste tipo de funções de ativação.

### 3.3.2 Formas de Aprendizagem Neural

A forma de aprendizado no domínio das RNAs é uma das características mais importantes do seu âmbito, sendo responsável pela capacidade de generalização e desempenho da rede neural utilizada (MHATRE *et al.*, 2017; FENG *et al.*, 2019).

É por meio do processo de aprendizado que as RNAs se adequam à execução de uma tarefa específica, sendo capaz de distinguir e prever padrões de dados futuros a partir de um conjunto de amostras históricas pré-processadas (GOODFELLOW; BENGIO; COURVILLE, 2016).

A aprendizagem de uma RNA consiste no ajuste de seus pesos sinápticos, no qual, por meio de um processo iterativo de exposição da rede à estímulos externos, essa se adapta ao conjunto de dados utilizado durante a fase de treinamento.

Existem diversos paradigmas em aprendizado de máquina que são aplicados as redes neurais artificiais, sendo cada um deles sujeitos ao modo de como os pesos sinápticos são atualizados e quais são as informações disponíveis para treinamento (FENG *et al.*, 2019; WANG *et al.*, 2019). No entanto, dentre os principais paradigmas de aprendizado, que são direcionados às aplicações de RNAs, se encontram: a aprendizagem supervisionada, a aprendizagem não-supervisionada e a aprendizagem por reforço (MHATRE *et al.*, 2017).

No aprendizado supervisionado, os dados de entrada são apresentados à rede neural na forma de pares ordenados, onde para cada valor de entrada é especificada uma única classe de saída desejada. Essa relação, é definida com base em conhecimentos prévios sobre os dados amostrados, o qual define ou classifica o tipo de dado a ser treinado (GOODFELLOW; BENGIO; COURVILLE, 2016).

Se a saída da rede neural diferir significativamente da saída desejada, o algoritmo de treinamento será responsável por ajustar os valores dos pesos sinápticos, a fim de minimizar a magnitude do erro absorvido pela rede.

Na aprendizagem supervisionada, a dinâmica de comparação entre a saída real e a saída desejada de uma RNA é repetida inúmeras vezes durante o processo de treinamento neural, no qual para cada comparação e passagem efetiva do dado por toda extensão da rede é considerada como “época” (MHATRE *et al.*, 2017).

No entanto, nem todos os tipos de dados fornecem uma prévia de suas características de separabilidade, quer seja por sua complexidade funcional e/ou natureza do dado amostrado. Assim sendo, o aprendizado supervisionado nem sempre se demonstra factível, necessitando o emprego de outros modos de aprendizagem (WANG *et al.*, 2019).

No aprendizado não-supervisionado nenhuma informação prévia dos dados de treinamento é utilizada, isto é, os dados de entrada são apenas agrupados tomando-se por base as suas características semelhantes. Para tanto, a arquitetura e o processo de treinamento da rede neural caracterizam-se, respectivamente, por utilizar neurônios classificadores e usualmente ser competitivo e inibitório (KOHONEN, 1990; GOODFELLOW; BENGIO; COURVILLE, 2016).

O aprendizado não-supervisionado se fundamenta no modo como o córtex cerebral humano distingue diferentes objetos por suas características principais, seja por meio de

sua agrupação em classes ou exclusão definitiva. Dessa forma, a rede possui atributos que lhe conferem à auto-organização e abstração de dados (KOHONEN, 1990).

Já no aprendizado por reforço, o ajuste dos pesos sinápticos é executado com relação as limitações ou informações que a rede possui sobre seu ambiente externo e/ou ações que efetua. Isto é, em uma primeira instância, à rede neural considerada como agente avaliador, executa decisões totalmente aleatórias e, com o passar do tempo suas escolhas (políticas) são ponderadas com base nos resultados de suas ações anteriores (GOODFELLOW; BENGIO; COURVILLE, 2016).

Caso a execução de uma decisão seja eficiente em termos de classificação, a mesma será recompensada positivamente pela rede, no qual o ajuste dos pesos sinápticos se tornara mais sensível ao tipo de dado apresentado. Caso a decisão tomada seja inadequada, a rede agirá de forma a se tornar menos sensível ao dado utilizado (HAYKIN, 2007).

Outro critério para se classificar a forma de aprendizagem adotada por uma rede neural é se sua aprendizagem ocorre de forma instantânea (*online*) ou estática (*offline* ou em lote), independentemente do tipo de paradigma por ela adotado. Quando os parâmetros de um modelo neural são atualizados à medida que novos dados são adquiridos para avaliação, isso se dá como uma forma de aprendizado contínuo (ou *online*), em que um novo modelo da mesma arquitetura é gerado sequencialmente, sobrescrevendo partes de sua versão anterior (HOI *et al.*, 2018).

Já no aprendizado em lote, todos os dados que serão utilizados na construção do modelo neural são previamente estabelecidos e apenas um único modelo é feito a partir da abstração desses dados. Se uma nova instância de dados for disponibilizada, todo o conjunto de dados será reutilizado e usado no desenvolvimento de um novo modelo, não apenas sobrescrevendo suas partes atualizadas. Isso gera um custo computacional maior, pois é necessário, além da geração de novos modelos, armazenar todos os dados históricos utilizados.

O aprendizado contínuo se caracteriza por ser relativamente rápido, quando comparado ao aprendizado em lote, dada a sua capacidade de se adaptar instantaneamente às variações observadas (HOI *et al.*, 2018). Porém, para determinados tipos de problemas, tal adaptação pode ser prejudicial, pois a presença de *outliers* ou simples ruídos no conjunto de dados avaliado pode gerar erros significativos, reduzindo a eficácia do modelo (GOODFELLOW; BENGIO; COURVILLE, 2016).

Algumas abordagens mais simples, como a redução da taxa de aprendizado, podem ser aplicadas para se obter uma melhor resposta por meio do aprendizado contínuo, porém, o uso do aprendizado em lote, quando as características do conjunto de dados são inicialmente desconhecidas, pode gerar resultados mais satisfatórios. Entretanto, o tamanho do lote (*batch\_size*) utilizado no treinamento também pode causar perda de acurácia nos

modelos neurais, dada sua influência na convergência da rede durante esta etapa (DUCHI; SINGER, 2009).

Quando o tamanho de *batch\_size* empregado é relativamente pequeno ou grande, isso pode resultar, respectivamente, em uma convergência extremamente lenta ou rápida, não sendo utilizável nem aplicável a certos tipos de problemas. Além disso, esse condicionamento pode nem mesmo atingir o ponto ideal de treinamento, permanecendo nos estados locais ou não atingindo um nível de treinamento adequado. Logo, nesse sentido, um valor de *batch\_size* oportuno pode ser difícil de se obter na prática (DUCHI; SINGER, 2009).

Apesar disso, ressalta-se que o tipo de aprendizado empregado é dependente da topologia de rede neural utilizada, sendo dessa forma muito restrita ao tipo de problema a ser tratado.

### 3.3.3 Processo de Treinamento das RNAs

Em virtude da sua capacidade de generalização de características, as RNAs se mostram uma alternativa tangível para a resolução de problemas complexos (YU *et al.*, 2015). Essa capacidade, segundo (RUMELHART; HINTON; WILLIAMS, 1986), é obtida por meio de um processo iterativo, no qual, através da aplicação do algoritmo de treinamento, os parâmetros do modelo neural são otimizados para obter a melhor aproximação do problema observado.

Além disso, de acordo com HAYKIN (2007), em problemas de classificação e regressão de dados, o ajuste dos parâmetros locais de uma RNA é comumente realizado utilizando um algoritmo de retropropagação do erro, também conhecido como *backpropagation* (LECUN *et al.*, 1988; HAYKIN, 2007). Esse algoritmo é responsável por verificar o nível de desempenho da rede neural e, se esse nível estiver abaixo das expectativas, o mesmo ajustará seus parâmetros locais (pesos sinápticos e bias), a fim de melhorar a assertividade do modelo (HAFEMANN, 2014).

No *backpropagation*, o processo de aprendizado ocorre em duas etapas (RUMELHART; HINTON; WILLIAMS, 1986). No primeiro estágio, chamado *forward*, o sinal de entrada é propagado por toda a extensão da rede neural, camada por camada, até a última camada de saída, com a ativação local de cada neurônio (HAYKIN, 2007; FARIA, 2018). Essa etapa é mantida até que um sinal de resposta seja exibido pela rede (SULIMAN; ZHANG, 2015).

Após a fase *forward*, a resposta do modelo neural, geralmente dada como um vetor de probabilidades, é então comparada à algum padrão esperado, com uma função de perda sendo definida no final do processo (RUMELHART; HINTON; WILLIAMS, 1986).

Em tarefas de classificação supervisionada, algumas das principais formulações para as funções de perda podem ser encontradas na Tabela 3.1, onde  $y$  representa a saída alcançada pela rede e  $t$  o valor desejado pelo modelo (ZHAO *et al.*, 2016).

Tabela 3.1 – Principais funções de perda utilizadas no treinamento de redes neurais artificiais.

Nome da Função de Perda	Formulação Matemática
RMSE	$L(y, t) = \frac{1}{2k} \sum_{i=1}^k \sqrt{(t_i - y_i)^2}$
Erro Médio Absoluto (MAE)	$L(y, t) = \frac{1}{2k} \sum_{i=1}^k  t_i - y_i $
<i>Crossentropy</i>	$L(y, t) = -\sum_{i=1}^k (t_i * \ln(y_i) + (1 - t_i) * \ln(1 - y_i))$

Fonte: O autor (2021).

Em geral, quando a resposta da rede neural é dada como um vetor de probabilidades, aplica-se a função *Crossentropy*, pois essa permite uma melhor análise das duas distribuições observadas (RAMOS NETO, 2018). Após o cálculo da função de erro, o algoritmo executa uma medida de desempenho global, segundo a equação (3.2),

$$E_j(w, b|x, t) = \frac{1}{n} \sum_{i=1}^n L(\varphi(w_i x_i + b), t) \quad (3.2)$$

onde  $n$  representa a quantidade de neurônios na última camada,  $\varphi$  a função de ativação utilizada nesses neurônios,  $L$  a função de perda avaliada e  $E$  o erro mensurado para uma dada interação  $j$  do algoritmo de treinamento.

O objetivo do processo de treinamento é fazer com que a rede aprenda com os dados, reduzindo a discrepância entre o valor calculado pela RNA e o resultado correto a ser identificado (SULIMAN; ZHANG, 2015). Assim, treinar uma rede neural, com o algoritmo de *backpropagation*, consiste em encontrar parâmetros  $w$  e  $b$  que minimizem sua função de erro global (BUSCEMA, 1998).

Como as redes neurais são uma composição de funções em nós, paralelos e fortemente conectados, uma abordagem analítica para o problema de minimização não é viável. Desta forma, o método de otimização numérica conhecido como *Gradient Descent* é geralmente aplicado (SULIMAN; ZHANG, 2015; RUDER, 2016).

Sabe-se do Cálculo Vetorial que o gradiente de uma função diferenciável  $f$  aponta para sua direção de maior crescimento e é perpendicular às suas curvas de nível (VANDER-PLAATS, 1984). Assim, torna-se possível minimizar  $f$ , com base na direção reversa do gradiente, em um processo iterativo de ajuste de seus parâmetros locais (FARIA, 2018). Essa adaptação computacional de pesos e *bias* é realizada conforme a equação (3.3),

$$\begin{cases} \Delta w_{jki} = -\eta \frac{\partial E_j}{\partial w_{jki}} \\ \Delta b_{jki} = -\eta \frac{\partial E_j}{\partial b_{jki}} \end{cases} \quad (3.3)$$

onde  $\frac{\partial E_j}{\partial w_{jki}}$  e  $\frac{\partial E_j}{\partial b_{jki}}$  representam, respectivamente, as derivadas parciais da função de erro em

relação aos pesos sinápticos e *bias*, para um neurônio  $i$  da camada  $k$  de uma rede neural e,  $\eta$  é dada como uma taxa de aprendizado, com um valor entre 0 e 1, que controla o percentual de ajuste dos parâmetros.

A próxima fase do algoritmo *backpropagation* é denominada por *backward*, que permite que os pesos sinápticos das camadas intermediárias (ocultas) sejam atualizados (SULIMAN; ZHANG, 2015). Para isso, os valores de erro encontrados na etapa anterior são propagados na direção oposta à camada de saída e, em seguida, o ajuste dos parâmetros é aplicado, individualmente em cada neurônio.

No entanto, para as camadas intermediárias, é necessário aplicar a regra da cadeia, pois para essas, o gradiente da função de erro será derivado em relação a saída do neurônio artificial ( $y_{jki}$ ), que por conseguinte será derivado em relação a saída da função de ativação ( $\varphi_{jki}$ ), a qual, por fim, é derivada em relação aos parâmetros do neurônio avaliado (SULIMAN; ZHANG, 2015). O resultado deste cálculo é dado de acordo com a equação (3.4),

$$\left\{ \begin{array}{l} \frac{\partial E_j}{\partial w_{jki}} = \frac{\partial E_j}{\partial y_{jki}} \cdot \frac{\partial y_{jki}}{\partial \varphi_{jki}} \cdot \frac{\partial \varphi_{jki}}{\partial w_{jki}} \\ \frac{\partial E_j}{\partial b_{jki}} = \frac{\partial E_j}{\partial y_{jki}} \cdot \frac{\partial y_{jki}}{\partial \varphi_{jki}} \cdot \frac{\partial \varphi_{jki}}{\partial b_{jki}} \end{array} \right. \quad (3.4)$$

De uma maneira simplificada, em cada etapa de propagação e retropropagação, os vetores de pesos e *bias* são alterados na direção de maior queda ao longo da superfície do erro. Esse processo continua até que seja atingido um erro local mínimo ou a quantidade máxima de interações (BUSCEMA, 1998).

### 3.3.4 Regularização *Dropout*

Conforme discutido na Seção 3.3.3, o treinamento de uma RNA é realizado para que o modelo possa aprender com os dados, delimitando estruturas intrínsecas que lhe permitem executar tarefas de natureza complexa (NIELSEN, 2015). Dessa forma, se adequadamente treinadas, as RNAs podem apresentar um bom desempenho em aplicações reais, sendo capazes de identificar certos tipos de características em amostras que não foram usadas durante o processo de treinamento (NIELSEN, 2015). Este é considerado o cenário ideal para um problema de *deep learning*. No entanto, isto nem sempre acontece.

Se o número de parâmetros de uma RNA for muito pequeno em relação à complexidade do problema observado, essa estará sujeita a um sub-ajuste (*underfitting*) dos seus parâmetros locais, ou seja, a rede neural avaliada terá uma baixa capacidade de aprendizado, deixando de abstrair as informações contidas em dados mais complexos (JABBAR; KHAN, 2015).

Por outro lado, se o número de parâmetros de uma RNA for excessivo, a mesma es-

tará sujeita a um sobre-ajuste (*overfitting*) do seu processo de treinamento, resultando em um desempenho extremamente eficiente durante esta fase, porém apresentando um fraco comportamento para novas amostras ainda não avaliadas (SRIVASTAVA *et al.*, 2014). Isto é, o modelo se adequa aos parâmetros livres (geralmente numerosos) do problema e falha em abstrair diferentes tipos de dados, se não aqueles usados na fase de treinamento.

Uma maneira de resolver esses problemas é construir uma rede relativamente grande, um pouco maior que o necessário, para obter um bom desempenho na fase de treinamento e, ao mesmo tempo, garantir que o processo de *underfitting* não ocorra (JABBAR; KHAN, 2015). Em seguida, para evitar o *overfitting*, um ou mais esquemas de regularização podem ser aplicados para se obter um melhor recurso de generalização (HINTON *et al.*, 2012).

Na prática, a capacidade de generalização de uma RNA é verificada através da adoção de um conjunto de teste, no qual amostras não utilizadas no processo de treinamento são usadas para constatar a assertividade do modelo construído (NIELSEN, 2015). Uma forma de detectar *overfitting* nesse processo, é adotar um terceiro conjunto de dados, geralmente chamado de conjunto de validação. Este conjunto é usado em cada estágio do processo de treinamento para calcular uma medida de erro do modelo para os dados do conjunto de validação (BALDI; SADOWSKI, 2014).

Caso haja a ocorrência de *overfitting*, o erro calculado para os dados de treinamento tende a diminuir a cada estágio do processo de treinamento, enquanto que para aqueles do conjunto de validação, o mesmo tende a aumentar (NIELSEN, 2015). Nesse momento, o modelo para de aprender e apenas "memoriza" o conjunto de treinamento. Assim, uma prática comum é o término abrupto do processo de treinamento. Essa prática é chamada de *early stopping* e, ocorre quando o erro observado no conjunto de validação aumenta após um certo número de épocas (ABU-MOSTAFA; MAGDON-ISMAIL; LIN, 2012).

Outra forma de regular uma RNA é aplicando uma penalidade na sua função de custo a cada momento do processo de treinamento (NIELSEN, 2015). Assim, é induzida uma adaptação do número de pesos sinápticos, alterando a função de erro de acordo com a equação (3.5),

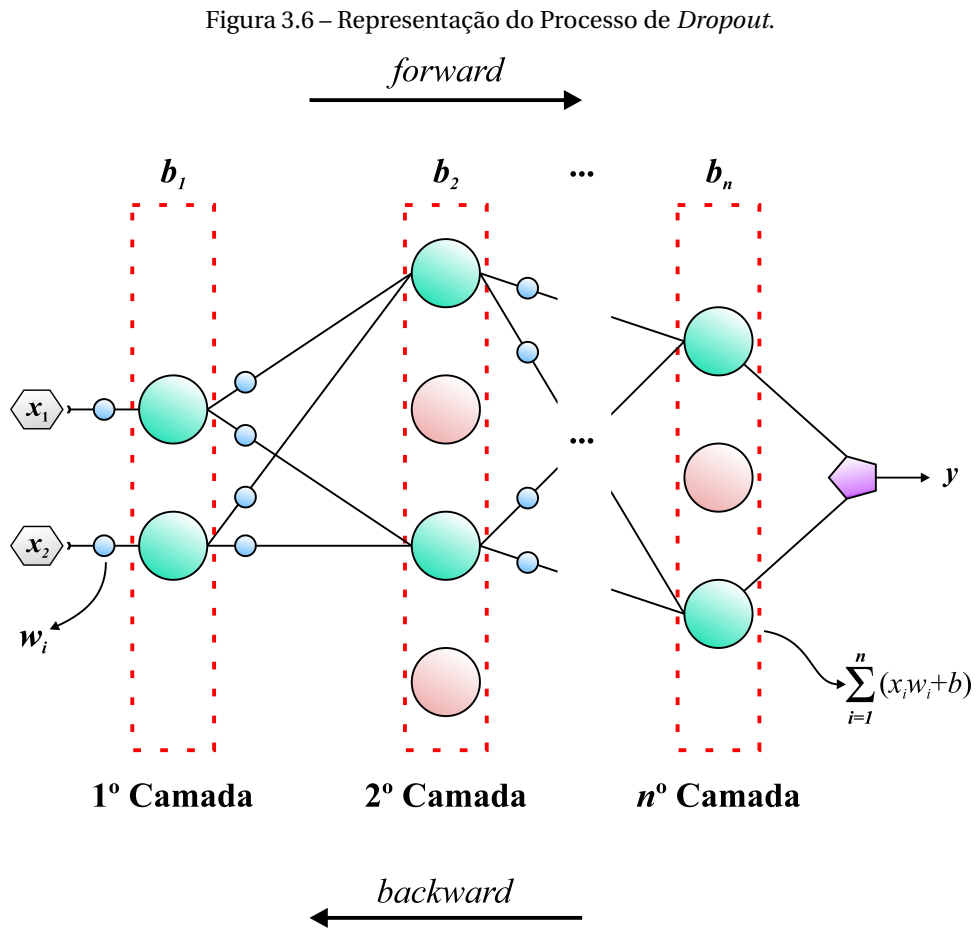
$$\hat{L}(y, t) = L(y, t) + \lambda r(w) \quad (3.5)$$

onde  $\lambda$  é um hiperparâmetro que indica a penalização do parâmetro avaliado e  $r$  é dada como uma norma deste (JABBAR; KHAN, 2015; PHAISANGITTISAGUL, 2016). Entre as principais normas utilizadas em RNAs estão a  $L1$  e a  $L2$ , expressas de acordo com as equações (3.6) e (3.7), respectivamente,

$$r(w) = \|w_i\| = \sum_{i=1}^n |w_i| \quad (3.6)$$

$$r(w) = \frac{\|w_i\|^2}{2} = \frac{1}{2} \sum_{i=1}^n w_i^2 \quad (3.7)$$

Embora as práticas de regularização mencionadas anteriormente apresentem resultados suficientes para proporcionar uma melhor generalização dos dados, outra técnica desenvolvida por [Hinton et al. \(2012\)](#) têm se destacado nos últimos anos. Essa técnica é chamada de *Dropout* ([BALDI; SADOWSKI, 2014](#)) e pode ser representada graficamente conforme a Figura 3.6.



Fonte: O autor (2021).

A técnica *Dropout* consiste em uma inibição temporária de certos neurônios da arquitetura neural utilizada, sendo esses neurônios escolhidos aleatoriamente a cada momento do processo de treinamento ([HINTON et al., 2012](#)). Isso significa que a cada interação é selecionada uma nova configuração da mesma topologia desenvolvida, impondo ao modelo neural a necessidade de aprender estruturas mais gerais, ou seja, a RNA não fica dependente especificamente da ativação de certos neurônios para identificar padrões diferentes nos dados, tornando assim o modelo mais robusto ([BALDI; SADOWSKI, 2014](#)).

Devido à sua finalidade, a técnica *Dropout* é comumente aplicada às camadas intermediárias de uma RNA, principalmente após as camadas totalmente conectadas de uma CNN ([FARIA, 2018](#)). Nessas camadas, uma fração (geralmente dada por um hiperparâmetro  $\rho$ ) de seus neurônios é desconsiderada durante o processo de treinamento ([BALDI; SA-](#)

DOWSKI, 2014). Ou seja, suas conexões são omitidas durante a fase *forward* e seus parâmetros locais também não são ajustados durante a fase *backward* (SRIVASTAVA *et al.*, 2014).

Na Figura 3.6, os neurônios em vermelho representam aqueles que foram inativados pelo processo de *Dropout*, cuja escolha foi definida aleatoriamente com uma probabilidade  $\rho = 0.5$ . Cabe destacar, que a cada iteração do processo de treinamento, uma nova configuração para a escolha do *Dropout* é definida e que o processo utiliza apenas o conjunto de treinamento, não sendo realizado para os conjuntos de validação e de teste.

### 3.3.5 Maneiras de Avaliar a Eficácia de um Modelo Neural

Para verificar a capacidade de generalização de um modelo de *deep learning*, é comumente aplicada uma etapa de avaliação, que permite confirmar a adequação de seus parâmetros em relação às observações ainda não apresentadas durante seu treinamento (REICH; BARAI, 1999; PARMEZAN; SOUZA; BATISTA, 2019). Nesse sentido, métricas estatísticas são comumente empregadas, de modo a atestar a eficácia do modelo nas tarefas desempenhadas (OLIVERA *et al.*, 2017).

Assim, para tarefas de classificação, geralmente é avaliada uma medida de assertividade do modelo, que pode variar entre a exatidão, precisão, *recall* ou valor da métrica  $F_1$  nos seus resultados (em relação ao conjunto de dados de teste). Por outro lado, para as tarefas de regressão, apenas uma medida de acurácia desses resultados é comumente avaliada.

A medida de exatidão (equação 3.8) de um modelo neural, também conhecida como acurácia, representa em sua formulação a quantidade de dados que foram devidamente classificados pelo modelo, independentemente da classe avaliada, ou seja, em um problema de classificação, a métrica de exatidão é avaliada tanto na classe positiva<sup>1</sup> quanto nas classes negativas<sup>2</sup>.

$$acc = \frac{v_p + v_n}{v_p + v_n + f_p + f_n} \quad (3.8)$$

sendo:

- ✓  $v_p$  – a quantidade de dados da classe positiva classificados corretamente.
- ✓  $f_p$  – a quantidade de dados da classe positiva classificados erroneamente.
- ✓  $v_n$  – a quantidade de dados das classes negativas classificados corretamente.
- ✓  $f_n$  – a quantidade de dados das classes negativas classificados erroneamente.

Porém, deve-se observar que tal condicionamento pode causar erros de inferência quando o conjunto de dados das classes avaliadas é desproporcional, uma vez que a equação

<sup>1</sup> Classe Positiva – É a classe real a que pertence determinado dado de entrada, sendo verificada quando o modelo avalia corretamente a classificação desse dado.

<sup>2</sup> Classe Negativa – São as classes às quais os dados avaliados não pertencem, sendo verificada quando o modelo erra em sua classificação.

3.8 pode ser enviesada por valores irregulares de  $v_n$  e  $f_n$ , exigindo assim cautela quanto à sua verificação.

Ainda, outra forma de se mensurar a acurácia de um modelo neural, principalmente quando este é avaliado em problemas binários, é subtrair a probabilidade total de acertos (isto é 1) que tal modelo pode executar, da taxa de erros de sua predição sobre valores ainda não vistos por este modelo durante sua etapa de treinamento. Dessa forma, um segundo equacionamento para a formula de acurácia é dada de acordo com a equação 3.9.

$$acc_1 = 1 - E_i = 1 - \sqrt{(t_i - y_i)^2} \quad (3.9)$$

onde  $E_i$  representa a taxa de erro mensurada a partir da predição dos de teste,  $y_i$  o vetor de classes previstas pelo modelo neural e  $t_i$  o vetor de classes desejadas (*targets*) para o problema.

Por outro lado, a medida de precisão (equação 3.10) avalia apenas a assertividade do modelo, ou seja, mede apenas quantos valores da classe positiva foram corretamente classificados em relação ao conjunto total de dados indicados como valores da classe positiva (PARMEZAN; SOUZA; BATISTA, 2019). Isso reduz a dependência de proporcionalidade entre as classes, sendo de grande aplicabilidade em problemas dessa natureza (GOODFELLOW; BENGIO; COURVILLE, 2016).

$$prec = \frac{v_p}{v_p + f_p} \quad (3.10)$$

Ressalta-se também que tanto os valores de precisão quanto os de acurácia são medidos entre 0 e 1, onde valores mais próximos de 1 representam boa assertividade do modelo para novos dados e valores mais próximos de 0 representam baixa capacidade de generalização por este modelo.

O *recall*, por sua vez, pode ser considerado como uma vertente de avaliação da precisão, em que apenas a quantidade de valores que foram corretamente classificados é medida. Assim, verifica-se se os valores alcançados por este modelo apresentam um bom nível de assertividade em relação ao problema.

A métrica  $F_1$ , por outro lado, representa uma proporcionalidade entre o *recall* e o nível de precisão, sendo calculada como o dobro da média harmônica entre eles. As equações 3.11 e 3.12 demonstram, respectivamente, a formulação matemática do *recall* e da métrica  $F_1$ .

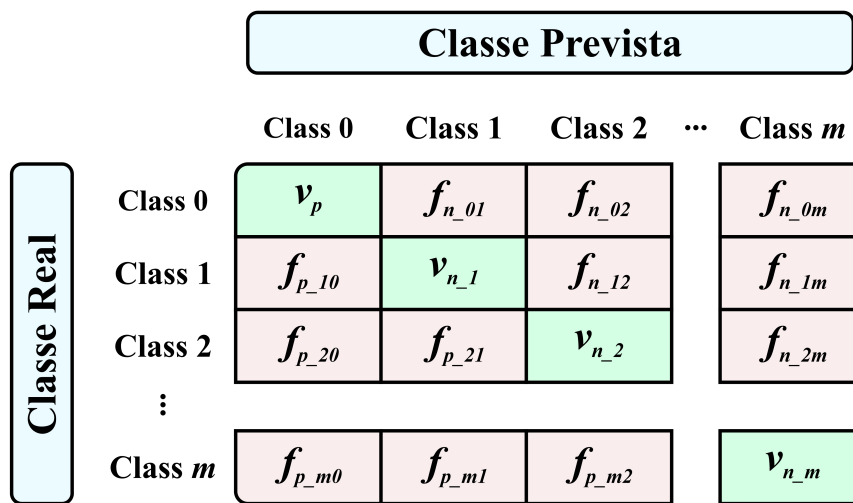
$$recall = \frac{v_p}{v_p + f_n} \quad (3.11)$$

$$F_1 = 2 \left( \frac{1}{\frac{1}{recall} + \frac{1}{prec}} \right) = 2 \left( \frac{prec \times recall}{prec + recall} \right) \quad (3.12)$$

Convém observar ainda que, embora a formulação matemática das medidas de desempenho acima mencionadas seja simples de se realizar, a escolha de qual dessas métricas deve realmente ser considerada para um determinado tipo de problema, pode ser difícil de fazer na prática, dada a complexidade de saber o que realmente influencia o modelo com os parâmetros avaliados. Assim, trabalhos recentes têm buscado novas formas de avaliação dos modelos de *deep learning*, definindo representações esquemáticas dos componentes de tais valores métricos.

A matriz de tabulação cruzada, também conhecida como matriz de confusão, é um dos principais meios de se representar de forma gráfica e tabulada os diferentes valores de frequência alcançados na classificação por um modelo de *deep learning*. Tal matriz é obtida comparando-se os valores previstos pelo modelo (em relação a um conjunto de dados de teste) com os valores reais, tentando assim delimitar uma relação entre acertos e erros do modelo de modo a delimitar sua capacidade de generalização (HARRISON, 2020). A Figura 3.7 mostra o *layout* geral de uma matriz de confusão.


Figura 3.7 – Esquemática de uma matriz de confusão para problemas de classificação multiclasse.



Fonte: O autor (2021).

A matriz de confusão mostrada na Figura 3.7, entretanto, permite apenas a visualização global do desempenho de um modelo neural. Outro meio de representação, embora exclusivo às métricas de recall e precisão, é a chamada *Receiver Operating Characteristic Curve* (ROC), que se dá por meio da representação de uma curva entre os valores dessas métricas (HARRISON, 2020). A Figura 3.8 apresenta um exemplo da curva ROC, em que a área sob tal curva é de 0.79.

Figura 3.8 – Exemplo de representação de uma curva ROC.



Fonte: Retirado de [Scikit-Learn \(2020\)](#).

Visto que as métricas de precisão e *recall* representam valores que a princípio são opostos, em que um alto valor de precisão é esperado em contraste à um baixo valor de *recall* (GOODFELLOW; BENGIO; COURVILLE, 2016). Assim, para valores de inclinação acima de 45° o desempenho do modelo avaliado é considerado oportuno, tendo o ponto superior esquerdo como meta ideal. No entanto, para valores inferiores a 45° tal desempenho é considerado insuficiente.

## Capítulo 4

---

# Fundamentação Teórica sobre as Redes Neurais Convolucionais

---

Neste capítulo é abordado a formulação técnica das redes neurais convolucionais, cujo modelo de rede será um dos empregados no decorrer deste trabalho. Para tanto, será descrito desde a sua concepção teórica até a sua descrição topológica e, posteriormente, a sua exemplificação de implementação computacional na análise de integridade estrutural.

Entretanto, antes de se introduzir o conceito das CNNs, será apresentado formalmente a operação matemática de convolução, a qual é especialmente utilizada pelas principais camadas da rede neural supracitada.

### 4.1 Convolução Discreta

Em processamento digital de sinais, a convolução discreta ou simplesmente convolução, é uma operação linear entre dois vetores que resultará na soma interna de seus produtos locais (DUMOULIN; VISIN, 2016; ZHAI *et al.*, 2016). Essa soma é em função da superposição dos índices e do deslocamento existente entre os vetores.

Segundo Sharma, Jain e Mishra (2018) a aplicação da técnica de convolução em matrizes, especificamente em imagens, possibilita a abstração de suas características peculiares tais como profundidade, bordas, detecção de formas, dentre outras.

Assim sendo, para se compreender a operação de convolução em sua totalidade, deve-se considerar três vetores  $x$ ,  $w$  e  $y$ , de tal forma que esses se correlacionem de acordo com a equação (4.1).

$$y(i) = \sum_{k=0}^{m-1} x(i+m-k) \cdot w(k) \quad (4.1)$$

onde  $x$  e  $w$  correspondem aos vetores que serão convolucionados e  $y$  ao vetor resultante da operação de convolução, sendo esse último comumente descrito na literatura como *feature*

*map* (YAMASHITA *et al.*, 2018).

Embora a operação de convolução possa ser utilizada em diversas situações matemáticas, fazendo-se analogia ao tema de redes neurais artificiais e já antecipando alguns conceitos das CNNs; o vetor  $x$ , descrito na equação (4.1), representa o sinal de entrada da camada convolucional, enquanto que o vetor  $w$  representa a matriz de filtro (*kernel*) utilizada para a abstração de características (MASSUCATTO, 2018).


Porém, deve-se salientar duas circunstâncias importantes dessa formulação. A primeira é relacionada a abstração dos valores de extremidades do sinal de entrada e a segunda é referente a inversão e ao deslocamento do *kernel* de abstração, isto é, do vetor  $w$ .

Para se aplicar uma convolução discreta, o *kernel* de abstração deve ser invertido e centralizado em cada índice do vetor de entrada. Tarefa essa, pode se tornar complexa à medida que se aproxima dos índices de extremidades, uma vez que estes não possuem vizinhos e as dimensões do *kernel* se mantenham constantes (MASSUCATTO, 2018).

Uma forma de se resolver o problema da inexistência de vizinhos nos extremos do vetor de entrada, e que por si é amplamente utilizada na literatura, é a inclusão de uma certa quantidade de zeros nas bordas do vetor  $x$ . Tal aplicação é popularmente conhecida como *padding* e possibilita a convolução dos valores extremos, sem proporcionar grandes ou nenhuma alteração no resultado final (MASSUCATTO, 2018; DUMOULIN; VISIN, 2016).

A Figura 4.1 apresenta as dimensões do vetor  $x$  antes e depois da aplicação do *padding*. Pode-se observar que o vetor sofreu um acréscimo de tamanho na ordem  $2p$ , onde  $p$  é quantidade de zeros aplicados em cada uma das extremidades do vetor  $x$ .

Figura 4.1 – Representação gráfica da operação de *padding* em um vetor  $x$  qualquer.



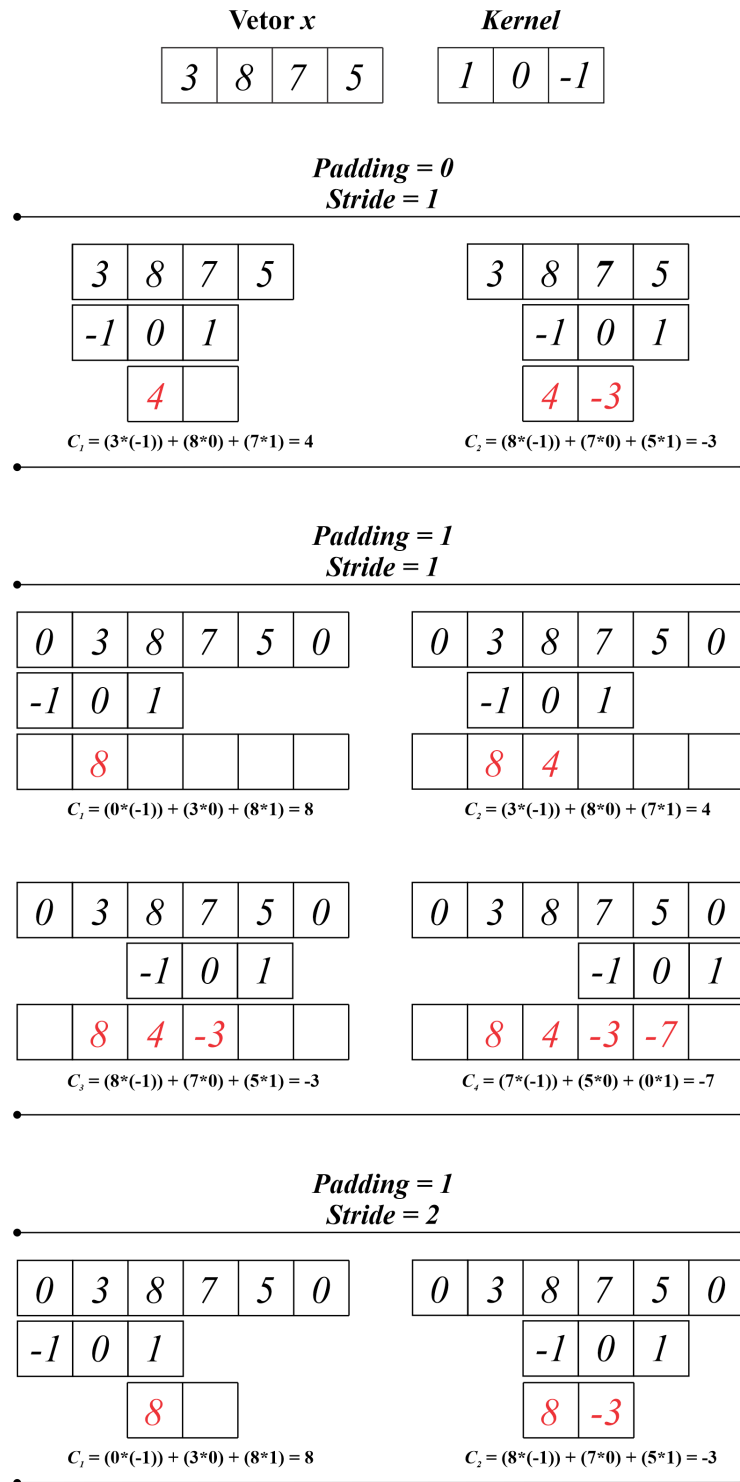
Fonte: O autor (2021).

Conforme supracitado, no processo de convolução entre dois vetores, sendo um deles o vetor de entrada e o outro o filtro de abstração, deve-se ter precauções quanto ao deslocamento entre esses. O deslocamento do *kernel* de convolução, denominado na literatura por *stride*, regulariza o nível de abstração e as dimensões da resposta final da operação de convolução. Sendo assim, o parâmetro *stride* é de fundamental importância para a eficiência da rede neural supracitada (MASSUCATTO, 2018; DUMOULIN; VISIN, 2016).

A Figura 4.2 apresenta o processo de convolução entre dois vetores com diferentes

valores de *padding* e *stride*, sendo que estes foram escolhidos aleatoriamente.

Figura 4.2 – Representação da operação matemática de convolução discreta.



Fonte: O autor (2021).

Pode-se observar na Figura 4.2 que as dimensões do resultado da convolução é dependente tanto da ordem de *padding* quanto do valor de deslocamento (*stride*) do *kernel* de abstração. A aplicação da operação de convolução discreta pode gerar a perda de algumas informações, uma vez que a matriz resultante (*feature map*) é dimensionalmente igual ou

inferior ao sinal de entrada. No entanto, a sua execução leva a detecção e a distinção das partes mais significantes de um sinal qualquer.

## 4.2 Redes Neurais Convolucionais

As Redes Neurais de Convolução (CNN) são arquiteturas especiais de aprendizagem profunda, voltadas ao tratamento e ao desenvolvimento de um conjunto específico de problemas da visão computacional, em especial à classificação de imagens e áudios (LETTRY *et al.*, 2017).

Sua formulação neurobiológica teve inspiração na organização e no processo como o córtex visual humano age na abstração de características de um determinado objeto. Para tanto, as CNNs possuem uma estruturação hierarquizada de suas camadas de neurônios, das quais em ao menos uma delas é aplicado a operação de convolução (GOODFELLOW; BENGIO; COURVILLE, 2016).

Segundo Faria (2018) a arquitetura do córtex visual humano é composta por diferentes níveis celulares de abstração, a qual foi essencialmente reproduzida pela arquitetura CNN. Neste contexto, camadas de níveis mais baixos são constituídas por modelos convolucionais, que são responsáveis pela separabilidade das pequenas parcelas de dados. Já as camadas de alto nível são compostas por modelos de subamostragem (*pooling*) e neurônios totalmente interligados, os quais sintetizam e classificam as informações que essas pequenas parcelas representam.

Camadas convolucionais, além de empregarem convoluções de seus pesos sinápticos (pelo uso de filtros de amostragem) apresentam apenas uma conectividade local entre o seu conjunto de neurônios artificiais e os núcleos de suas entradas.

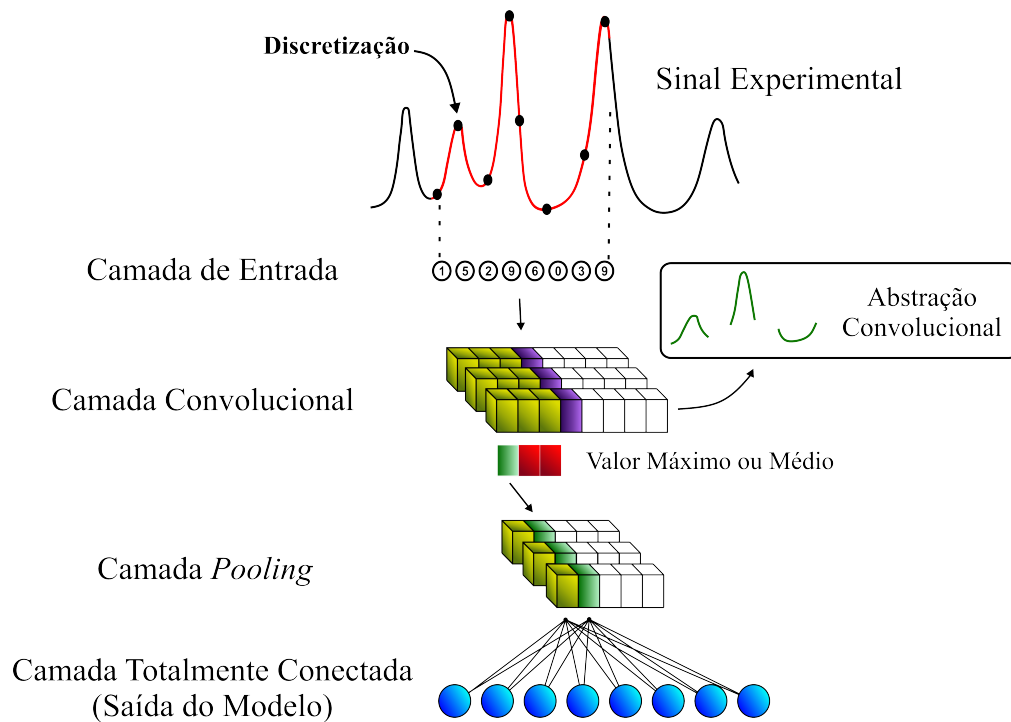
Já as camadas *pooling*, apresentam uma conectividade superior as convolucionais e servem como pontes detalhadas ao modelo de classificação da rede. Esse, por si, é responsável por catalogar e definir as possíveis saídas da rede, sendo que estas são definidas em classes ou probabilidades de pertencerem a um determinado grupo (KRIZHEVSKY; SUTSKEVER; HINTON, 2012).

A Figura 4.3 apresenta a topologia característica de um modelo de rede neural convolucional, sendo que nas seções posteriores serão abordados, de forma mais detalhada, os tipos de camadas de neurônios dessa rede e os seus respectivos dados de entrada e saída.

A classificação de um determinado dado amostral, por qualquer que seja o método classificatório, consiste na distinção da classe à qual ele pertence. Tarefa esta é considerada relativamente fácil para um cérebro humano, entretanto, ao se tratar de sua transcrição em linguagem de máquina, a mesma pode se configurar em uma tarefa complexa (BISHOP, 1995).

Por exemplo, quando uma imagem é amostrada a um computador, o mesmo a con-

Figura 4.3 – Arquitetura característica de uma rede neural convolucional unidimensional.



Fonte: O autor (2021).

sidera como uma matriz bidimensional (ou tridimensional a depender do seu tipo de colorização) de pixels, onde cada valor da matriz poderá variar entre 0 e 255. As redes convolucionais, ao invés de avaliarem toda extensão da matriz, subdividem-na de forma a extrair as principais características de cada setor, assim reduzindo o número de parâmetros livres a serem ajustados pela rede e subsequentemente otimizando o seu custo de treinamento (HE *et al.*, 2016).

Para tanto, as CNNs assumem que na topologia dos dados experimentais, os valores de índices mais próximos são bem mais correlacionados do que os valores de índices distantes. Ideal esse, que justifica a aplicação da técnica de convolução em imagens, áudios e demais conjunto de vetores.

Feng *et al.* (2019) aplicaram uma adaptação do modelo de rede neural convolucional, *Inception-v3*, para detectar danos estruturais em um sistema de junção-hidráulica. Para tanto, imagens de alta-resolução (pré-processadas) da estrutura foram utilizadas como entrada do modelo e, a partir de um processo de aprendizado por transferência, obtiveram uma precisão de 96.8% para detecção de danos nesse tipo de estrutura.

Ademais, os autores ressaltaram como aspecto importante das CNNs, a sua invariância a escala, translação e a outros tipos de transformações algébricas do conjunto de pixels amostrados. Isto é, a rede consegue definir e reconhecer os padrões de dados de forma bem mais abrangente e robusta do que as demais técnicas existentes na literatura (FENG *et al.*, 2019).

Ainda, para uma CNN, uma imagem computadorizada (ou outro tipo de dado vetorial) pode ser representada por meio de tensores geométricos, os quais descrevem as relações lineares entre suas coordenadas, valores escalares ou outros tensores da mesma imagem.

Essa possibilidade de retratação matemática por meio de tensores, facilitou amplamente a implementação das redes de convolução, bem como otimizou o seu custo computacional. Tal acontecimento decorre-se também ao desenvolvimento tecnológico das unidades GPUs, sendo essa disponibilidade computacional o principal contraste das atuais CNNs com os modelos implementados na sua época de criação (ABADI *et al.*, 2016; FARIA, 2018).

Fukushima (1975) foi o primeiro trabalho a abordar a técnica de convolução em redes neurais artificiais. Todavia, a sua forma de treinamento dos pesos sinápticos, diferentemente da que é atualmente empregada, se baseava em princípios de aprendizagem não supervisionada. Já o trabalho de LeCun *et al.* (1989) foi o primeiro a abordar o atual modelo de rede neural convolucional utilizado na literatura, o qual serviu de base para a construção de outras variantes das CNNs (KRIZHEVSKY; SUTSKEVER; HINTON, 2012; SIMONYAN; ZISSERMAN, 2014; YADAV; JADHAV, 2019).

A rede de LeCun *et al.* (1989) implementava uma arquitetura convolucional supervisionada com treinamento por *backpropagation*, sendo ela utilizada para a classificação de CEPs manuscritos. Porém, salienta-se que as limitações de *hardware* da época limitavam a operação do modelo de rede desenvolvido.

### 4.2.1 Camadas Convolucionais

As camadas convolucionais são constituídas pelo agrupamento de  $n$  filtros de abstração, em que cada filtro corresponde à apenas um subconjunto ou região do sinal de entrada (seja a entrada da própria rede ou a resposta de uma camada anterior). Isto é, os neurônios que compõe a camada convolucional são interconectados à apenas uma parte do sinal de entrada, sendo que esses coletivamente conseguem varrer toda extensão do mesmo (GOODFELLOW; BENGIO; COURVILLE, 2016; COFRE-MARTEL *et al.*, 2019).

Cada filtro de abstração é composto por uma grade (a depender de suas dimensões) de pesos sinápticos, os quais são inicializados de forma aleatória e posteriormente ajustados ao decorrer do processo de treinamento por *backpropagation* (KIM; RAJARAMAN; ANTANI, 2019).

Conforme a operação de convolução, para todos os deslocamentos (*strides*) dos *kernels* de abstração, o produto de cada elemento sobreposto (entre o próprio *kernel* e o sinal de entrada) é somado de forma a gerar uma determinada parte do *feature map*, o qual é definido como o conjunto de todas as características mais relevantes para aquela região (YAMASHITA *et al.*, 2018).

As dimensões da resposta de uma camada convolucional devem ser definidas de modo a não sobrepor a quantidade de neurônios da camada posterior e podem ser obtidas conforme a equação (4.2),


$$n_y = \left\lfloor \frac{n_x - n_k + 1}{d_{stride}} \right\rfloor \quad (4.2)$$

onde  $n_x$ ,  $n_k$  e  $n_y$  são, respectivamente, as dimensões do vetor de entrada, do *kernel* de abstração e da saída final; já o  $d_{stride}$  é o valor de deslocamento do *kernel*, sendo esse obrigatoriamente menor que  $n_x$ .

De modo simplificado, a camada convolucional define as localizações das informações mais significativas de um dado sinal amostral, seja ele uma imagem, áudio ou outro tipo de dado vetorial. No entanto, a sua capacidade de abstração está diretamente vinculada a certos tipos de paradigmas, tais como a conectividade esparsa, os campos receptivos locais e o compartilhamento de parâmetros livres (GOODFELLOW; BENGIO; COURVILLE, 2016).

A conectividade esparsa é decorrente do fato dos neurônios da camada convolucional estarem interligados à apenas uma região local das camadas adjacentes, uma vez que as dimensões do kernel de abstração são dimensionalmente inferiores às medidas do vetor de entrada. Isto é, diferentemente das redes MLPs (nas quais os neurônios de cada camada estão totalmente interligados as camadas adjacentes) as camadas convolucionais apresentam apenas uma relação pontual entre seus neurônios e os neurônios das camadas adjacentes, conforme pode ser observado na Figura 4.4.

Figura 4.4 – Representação da conectividade esparsa em camadas convolucionais.



Fonte: O autor (2021).

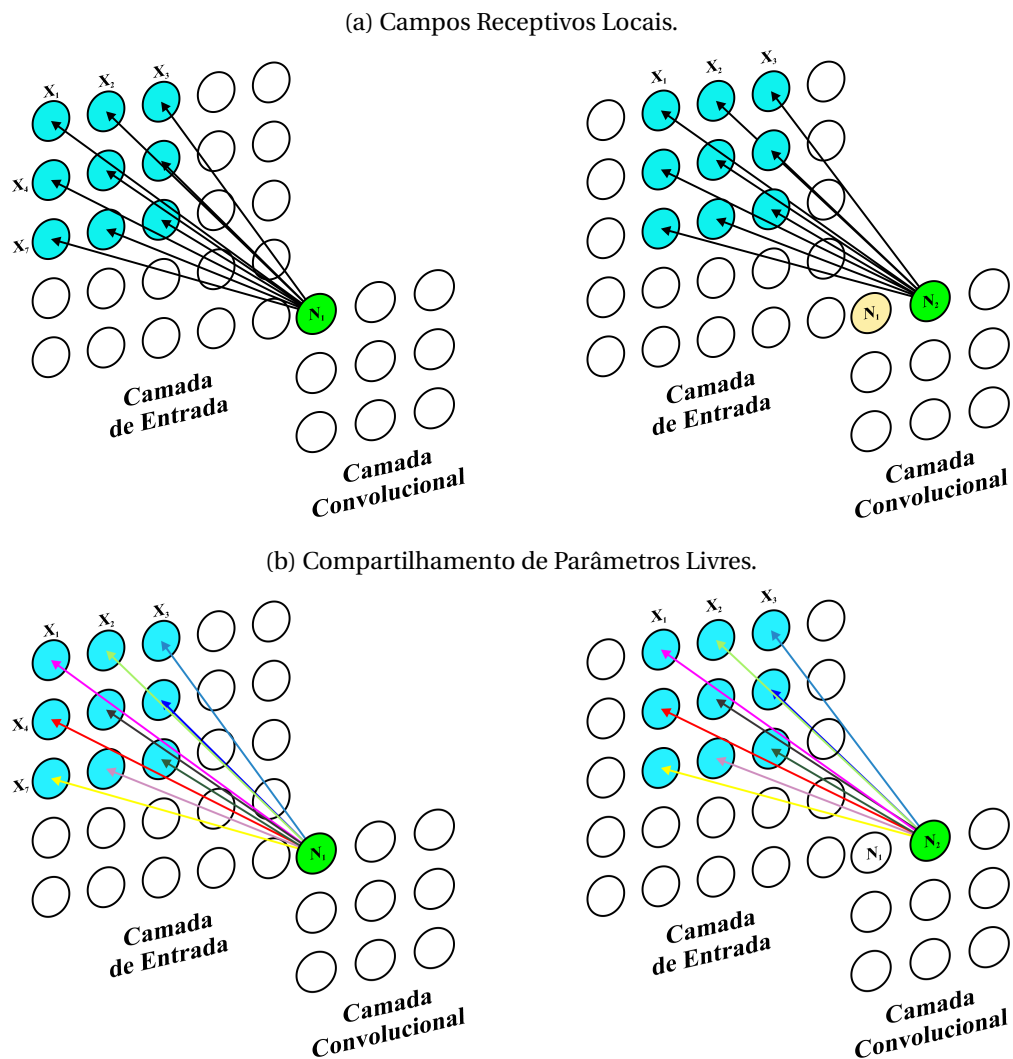
Já os campos receptivos locais e o compartilhamento de parâmetros livres são definidos não pela dimensionalidade do *kernel* de abstração, mas sim pelo seu deslocamento

em relação ao sinal de entrada. Isto é, cada sub-região do vetor de entrada possuirá ligação apenas com um único neurônio da camada sucessora, sendo que à medida que novos deslocamentos são efetivados ao *kernel* de abstração, novos neurônios (adjacentes) são então ativados.

Ao passo que novos deslocamentos são executados, alguns neurônios tendem a compartilhar as informações do *kernel* de abstração para outras regiões do vetor de entrada, uma vez que o filtro se mantenha constante em toda varredura do mesmo.

As Figuras 4.5a e 4.5b apresentam, respectivamente, exemplos de campos receptivos locais (neurônios em azul) e o compartilhamento de parâmetros livres (setas de cores iguais) entre sub-regiões do vetor de entrada.

Figura 4.5 – Ilustração gráfica de campos receptivos locais e compartilhamento de parâmetros livres em redes neurais convolucionais.



Fonte: O autor (2021).

Após ser realizada todas as convoluções do sinal de entrada, cada índice da matriz resultante (*feature map*) é então ativado conforme uma função de ativação. Dentre os variados

tipos de função de ativação existentes na literatura (Seção 3.3.1), o mais utilizado em camadas convolucionais é a função do tipo *ReLU*, a qual define a transmissão de apenas valores positivos (KUO, 2016).


## 4.2.2 Camadas *Pooling*

As camadas *pooling*, também conhecidas por camadas de subamostragem ou camadas de *downsampling*, são modelos especiais de camadas de neurônios artificiais capazes de reduzirem a quantidade de parâmetros livres de um *feature map* (FARIA, 2018; FENG *et al.*, 2019).

Estas camadas atuam como se fossem um filtro, possibilitando a transmissão somente das características consideradas mais relevantes (LEE; GALLAGHER; TU, 2016). Deste modo, parâmetros desnecessários são descartados durante o aprendizado da rede, o que contribui também para o controle de *overfitting* da mesma (O'SHEA; NASH, 2015).

Na literatura, foi abordada duas possibilidades básicas de operação para uma camada do tipo *pooling* (NAGI *et al.*, 2011; FENG *et al.*, 2019). A primeira, denominada por *MaxPooling*, realiza a abstração de todos os valores máximos de cada área do *feature map* e, subsequentemente, desconsidera as demais características deste (HIJAZI; KUMAR; ROWEN, 2015; WU, 2017). Isto é, a técnica abstrai apenas os valores máximos de cada sub-região, conforme é exemplificado na Figura 4.6.

Figura 4.6 – Abordagem de uma camada *pooling* pelo método de *MaxPooling*.

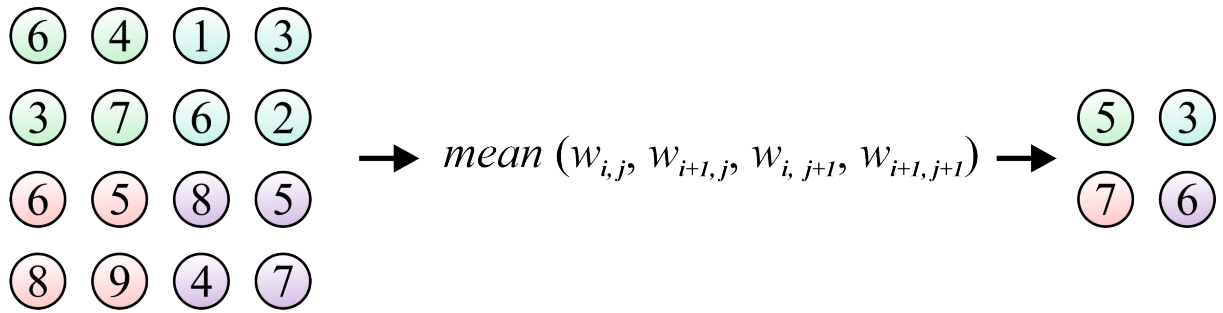


Fonte: O autor (2021).

Já a segunda abordagem conhecida por *Average-Pooling* ou *Mean-Pooling*, em contraste com a primeira, utiliza-se não dos valores máximos de cada sub-região, mas sim da média ponderada de todas as características que a constituem. A Figura 4.7 apresenta uma exemplificação da saída de uma camada *pooling* utilizando a abordagem por *Average-Pooling*.

É possível notar em ambas as imagens a redução da dimensionalidade de parâmetros livres, isto é, ocorreu a sintetização das informações de alto nível previamente abstraídas, sendo que as características remanescentes são descartadas durante o processo de treinamento da rede neural (WU, 2017; ZHANG *et al.*, 2018). Tal redução, igualmente às camadas convolucionais, é baseada nas dimensões e nos deslocamentos dos filtros de abstração so-

Figura 4.7 – Abordagem de uma camada *pooling* pelo método de *Average-Pooling*.



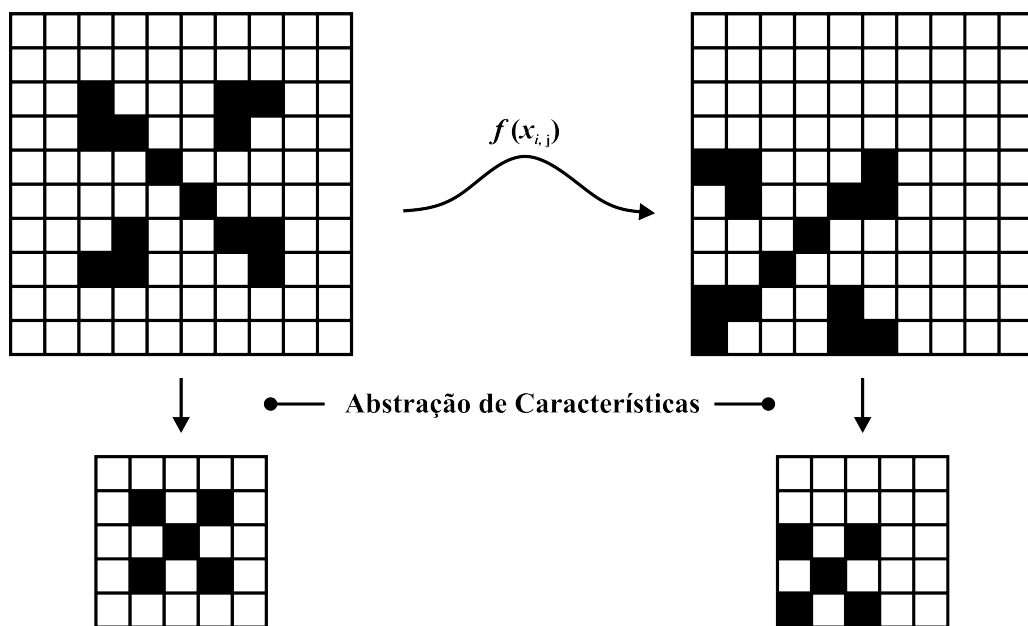
Fonte: O autor (2021).

bre as entradas da própria camada *pooling*, as quais são necessariamente caracterizadas por *feature maps* resultantes da camada convolucional antecessora.

Ademais, conforme supracitado, deve-se considerar que pelo fato da camada *pooling* abstrair apenas as características mais relevantes de cada sub-região (independentemente de sua localização); a presença da mesma possibilita que as CNNs sejam invariantes a escala, translação e a outros tipos de transformações algébricas no processo de visão computacional, em especial na classificação de imagens (LEE; GALLAGHER; TU, 2016; INDOLIA *et al.*, 2018).

A Figura 4.8 apresenta uma esquematização da invariância de uma camada neural do tipo *pooling*, em relação às transformações algébricas de uma imagem qualquer.

Figura 4.8 – Invariância das camadas *pooling* às transformações algébricas de imagens.



Fonte: O autor (2021).

Pode-se perceber que em ambos os casos a informação abstraída do sinal de entrada são idênticas ou proporcionais, demonstrando assim a propriedade de invariância das camadas *pooling*.

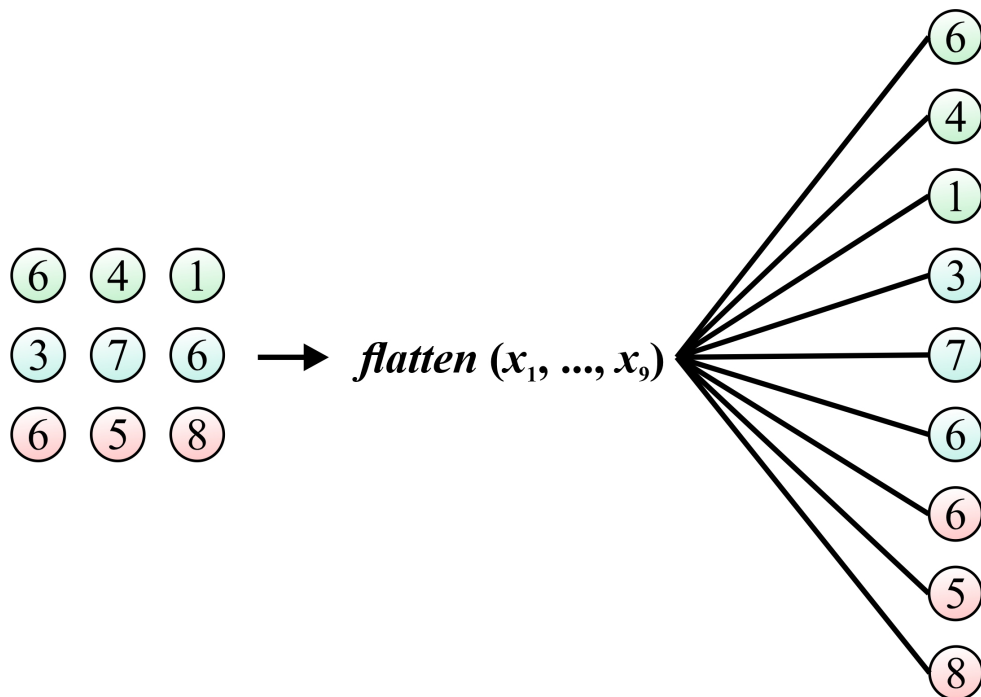
### 4.2.3 Camadas Totalmente Interligadas

Consideradas como o último componente da arquitetura convolucional, as camadas totalmente interligadas (ou do inglês *Fully Connected Layers*) constituem-se como um conjunto de duas ou mais camadas de neurônios artificiais, das quais todos os seus neurônios são globalmente interligados aos neurônios de suas camadas adjacentes (VARGAS; PAES; VASCONCELOS, 2016).

Para tanto, toda uma rede neural *feedforward* é integrada ao final do conjunto de camadas convolucionais e *pooling* de forma a maximizar o alcance do método classificatório, utilizando ao mesmo tempo as informações de alto nível previamente extraídas (VARGAS; PAES; VASCONCELOS, 2016).

Para que se possa ser feito o acoplamento das camadas totalmente interligadas, é obrigatoriamente adicionado uma subcamada de *flattening*, após a última camada *pooling*. Esta camada é responsável por padronizar o *feature map* em um vetor coluna, mantendo-se assim a integridade matemática do processo (CHOLLET, 2017). O vetor padronizado pela camada *flatten* é então utilizado como entrada do modelo classificatório *feedforward*. A Figura 4.9 demonstra um exemplo de padronização por meio de uma camada do tipo *flatten*.

Figura 4.9 – Padronização de um *feature map* por meio de uma camada *flatten*.



Fonte: O autor (2021).

Após um *feature map* ser remodelado pela camada *flatten*, o mesmo é propagado para as demais camadas ocultas da rede *feedforward* e, subsequentemente, a resposta de saída desta é comparada com uma classe objetivo. Caso a resposta difira significativamente, um sinal de retorno é propagado para as demais camadas antecessoras e, assim, os pesos si-

nápticos da rede são então ajustados, isto é, otimizados durante o processo de treinamento (PICZAK, 2015; SHARMA; GRANMO; GOODWIN, 2019).

A resposta da camada totalmente conectada é considerada como a própria saída da rede convolucional, a qual pode ser catalogada em classes (resultado determinístico) ou probabilidades de pertencerem a uma determinada classe (resultado probabilístico). Neste último, a função de ativação comumente utilizada na literatura é a do tipo *Softmax* (Seção 3.3.1), a qual descreve uma distribuição de probabilidade para a resposta da camada final (PICZAK, 2015; RAWAT; WANG, 2017; SHARMA; GRANMO; GOODWIN, 2019).

## Capítulo 5

---

# Fundamentação Teórica sobre a Rede LSTM

---

Este capítulo apresenta a formulação técnica da rede LSTM, que também será usada no desenvolvimento deste trabalho. Para isso, é discutida brevemente a necessidade de recorrência das informações que fluem em neurônios artificiais, descrevendo as formas atualmente implementadas para se realizar esse procedimento.

Posteriormente, é descrita a ideologia utilizada nas arquiteturas recorrentes, passando por seu processo de treinamento adaptado e concluindo com a descrição, propriamente dita, da arquitetura LSTM.

### 5.1 Necessidade de Recorrência no âmbito da RNAs


Em geral, para se caracterizar um sistema dinâmico, a análise de seu comportamento nas condições atuais não é suficiente, pois seu estado anterior geralmente influencia o seu estado atual (MANTOVANI, 2011). Neste contexto, as arquiteturas neurais do tipo *feed-forward* nem sempre se tornam aplicáveis, pois elas possuem apenas uma relação direta entre a entrada corrente e a sua respectiva saída.

Assim, com base nesse princípio, é necessário adicionar às RNAs algumas alterações em sua topologia, que lhes permitem armazenar uma relação temporal dos seus estados anteriores para a sua avaliação atual (MANTOVANI, 2011; BISPO, 2018).

Entre as várias modificações possíveis, duas se destacam, que são elas: os atrasos na entrada da rede e o processo de recorrência (MANTOVANI, 2011). Atrasos na entrada de uma RNA consistem basicamente no uso de amostras com dependência temporal, que são compostas juntamente com seus estados anteriores (ZHAO, 2016), como mostra a Figura 5.1.

Pode-se notar na Figura 5.1, que a aplicação da técnica de atraso é realizada apenas

Figura 5.1 – Exemplificação gráfica do processo de atraso na entrada de uma RNA.



Fonte: O autor (2021).

na entrada geral da rede neural utilizada. Dessa forma, a arquitetura RNA mantém-se do tipo *feedforward*, o que facilita o seu processo de implementação.

Essa alternativa de adaptação, no entanto, é aplicável apenas em sistemas de média complexidade, pois para sistemas de alta complexidade são necessárias estruturas internas de variação de estado, o que é alcançado através da aplicação de recorrência entre os neurônios de uma RNA (MANTOVANI, 2011).

A propriedade de recorrência, em uma RNA, é dada pela presença de ciclos entre suas unidades de processamento, isto é, a saída de um neurônio da  $n$ -ésima camada é utilizada como entrada para um neurônio de uma camada de nível inferior e/ou da própria camada, atribuindo uma realimentação na arquitetura que servirá como um mecanismo de memória a curto prazo (LE *et al.*, 2019).

O efeito prático da recorrência em RNAs é dinamizar os modelos neurais ao longo do tempo, fazendo com que as características observadas fluam em ambas as direções de propagação e, ao mesmo passo, sendo capaz de abstrair novas informações através de parâmetros já mensurados (WERBOS, 1988). Quando uma rede neural é construída com neurônios retroalimentados, ela é chamada de Rede Neural Recorrente (RNN – do inglês *Recurrent Neural Network*) e é caracterizada como uma topologia do tipo *feedback* (RUMELHART; HINTON; WILLIAMS, 1986).


## 5.2 Redes Neurais Recorrentes

As Redes Neurais Recorrentes (RNNs) são arquiteturas de aprendizagem profunda, que incluem certos mecanismos de memória, através do *feedback* de suas unidades internas de processamento (LE *et al.*, 2019; ZHANG *et al.*, 2019). Esse recurso, de acordo com Bispo (2018), oferece às RNNs uma melhor capacidade de reconhecer e prever diferentes tipos de padrões em longas cadeias de dados sequenciais (BALDI *et al.*, 2000; ZHAO *et al.*, 2016).

Assim, conforme descrito na Seção 5.1, elas são compostas de neurônios recorrentes que realizam, a cada interação do processo de treinamento, uma retroalimentação de suas informações abstraídas para outras partes do modelo de rede neural (ZHANG *et al.*, 2019). Portanto, se o processo de treinamento de uma RNA for considerado como um fluxo de memória a longo prazo, a recorrência no escopo das RNNs lhes permitirá operar em problemas muito mais complexos, aplicando conjuntamente recursos de longo e a curto prazo (HOCHREITER; SCHMIDHUBER, 1997).

Para melhor elucidar o fluxo de informações em uma RNN, a Figura 5.2 demonstra o processo de recorrência em um de seus neurônios característicos (BENGIO; SIMARD; FRASCONI, 1994). Nesta imagem, o neurônio artificial processa a entrada  $x(t)$  para gerar como resposta o vetor  $y_t$  (também conhecido como estado da rede no tempo  $t$ ).


Figura 5.2 – Representação do processo de recorrência em um neurônio artificial.



Fonte: O autor (2021).

O *loop* empregado na Figura 5.2 delimita a capacidade de transferir informações entre os estágios de processamento da rede neural. Assim, com base em uma entrada  $x(t)$ , com  $t$  variando de 1 a  $\tau$ , a representação de todo o processo de aprendizado de uma RNN é dada de acordo com a Figura 5.3.

Figura 5.3 – Representação do fluxo de aprendizado em uma RNN.



Fonte: O autor (2021).

Na Figura 5.3, o procedimento  $U$  é caracterizado apenas como um desdobramento do processo de aprendizado da RNN, decompondo a sua forma recorrente em uma forma sequencial (ZHANG *et al.*, 2019; SHERSTINSKY, 2020).

À medida que novas entradas são computadas pela rede neural no instante de tempo  $t$ , uma função de ativação  $g$  é aplicada em seu estado anterior ( $s_{t-1}$ ), mapeando sua contribuição para um novo estado ( $s_t$ ) da RNN (BISPO, 2018). Tais estados são considerados como os respectivos mecanismos de memória das redes recorrentes, pois esses são responsáveis por reterem, iterativamente, as informações históricas do processo de aprendizado da rede (ZHAO, 2016).

Ao passo que a operação de recorrência é realizada, a propagação dos valores internos de cada componente do neurônio artificial é processada de acordo com a equação (5.1),

$$\begin{cases} s_t = g((w \cdot x_t) + (u \cdot s_{t-1})) \\ y_t = \varphi(s_t + b) \end{cases} \quad (5.1)$$

onde  $u$  é dada como uma matriz de transição do estado oculto anterior ( $s_{t-1}$ ),  $g$  e  $\varphi$  são funções de ativação (tipicamente não-lineares) e  $s_t$  é atualizado com base em sua entrada atual e no estado anterior do neurônio avaliado.

### 5.3 Treinamento de uma RNN por *Backpropagation Through Time*

Conforme discutido na Seção 3.3.3, a eficiência de uma RNA é alcançada por meio de seu processo de treinamento iterativo, no qual os parâmetros do modelo são otimizados (usando o método do Gradiente Descendente) para se obter a melhor resolução do problema avaliado (HOCHREITER *et al.*, 2001).

No método do Gradiente Descendente, a responsabilidade do erro é fragmentada entre os parâmetros da RNA, por meio de suas derivadas parciais, para minimizar sua magnitude em cada iteração do processo de treinamento (SHERSTINSKY, 2020).

As RNNs, no entanto, são dadas também em função do seu estado oculto ( $s_t$ ), que por sua vez é obtido recorrentemente pelo seu estado anterior ( $s_{t-1}$ ) (HOCHREITER; SCHMIDHUBER, 1997). Dessa forma, a regra da cadeia exercida pelo algoritmo de *backpropagation* também deve ser decomposta em seu estado temporal  $s_t$ , uma vez que este não é considerado constante.

Por esse motivo, para as camadas intermediárias, o algoritmo de retropropagação apresentado na Seção 3.3.3 é parcialmente modificado, levando em consideração a regra da cadeia de acordo com a equação (5.2),

$$\begin{cases} \frac{\partial E_{jt}}{\partial w_{jkit}} = \frac{\partial E_{jt}}{\partial y_{jkit}} \cdot \frac{\partial y_{jkit}}{\partial \varphi_{jkit}} \cdot \frac{\partial \varphi_{jkit}}{\partial s_{jkit}} \cdot \frac{\partial s_{jkit}}{\partial w_{jkit}} \\ \frac{\partial E_{jt}}{\partial s_{jkit}} = \frac{\partial E_{jt}}{\partial y_{jkit}} \cdot \frac{\partial y_{jkit}}{\partial g_{jkit}} \cdot \frac{\partial g_{jkit}}{\partial s_{jkit}} \cdot \frac{\partial s_{jkit}}{\partial s_{jki(t-v)}} \end{cases} \quad (5.2)$$

onde  $v$  representa o índice para o qual o estado oculto será retro-propagado.

Devido a essa modificação, o algoritmo de retropropagação passa a ser considerado como *Backpropagation Through Time* (BTT) (LE *et al.*, 2019). A adaptação do processo de treinamento, atribuída pela equação (5.2), permite agregar a dependência dos núcleos de recorrência presentes nas RNNs, o que se torna de especial interesse na análise de vetores sequenciais, tais como séries temporais e cadeias de palavras (BISPO, 2018).

Deve-se notar, no entanto, que, para longas sequências de valores, os gradientes medidos pelo BTT tendem a se tornar nulos, pois são propagados recursivamente até que o índice de tempo  $t$  se torne 0, o que favorece o chamado *Vanishing Gradient Problem* (HOCHREITER; SCHMIDHUBER, 1997; ZHAO *et al.*, 2016; SHERSTINSKY, 2020). Tal eventualidade causa uma incapacidade no modelo de aprender novas informações do conjunto de dados, uma vez que os seus pesos sinápticos e *bias* não se ajustam assertivamente durante o processo de treinamento (HOCHREITER, 1998).

Assim, nos últimos anos, diversas soluções foram propostas para se evitar a anulação do gradiente, criando versões especializadas das RNNs (LE *et al.*, 2019). Uma das mais notórias e amplamente utilizadas é conhecida como *Long Short-Term Memory* (LSTM), que será descrita em mais detalhes na próxima seção.

## 5.4 Arquitetura LSTM

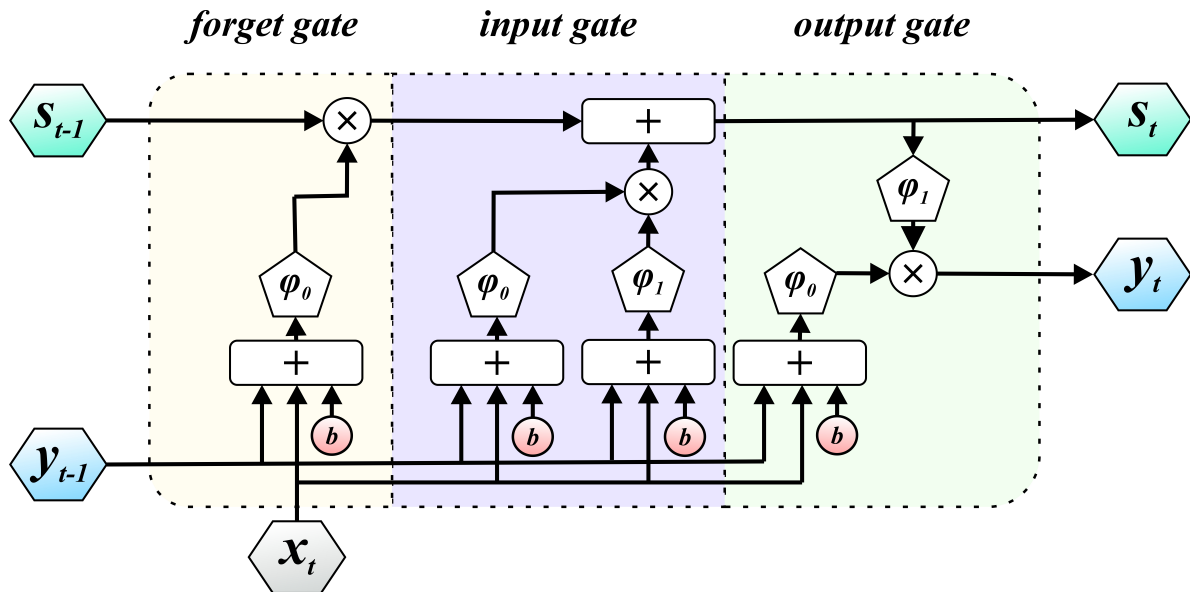
A arquitetura LSTM é um modelo de rede neural recorrente desenvolvido em 1997 pelos cientistas da computação Sepp Hochreiter e Jürgen Schmidhuber, a fim de resolver o problema do desaparecimento do gradiente descendente, quando um grande volume de dados sequenciais é avaliado (HOCHREITER; SCHMIDHUBER, 1997; ZHAO, 2016; LE *et al.*, 2019). Para isso, o fluxo de erro calculado durante o processamento da rede é mantido constante através da inclusão de unidades especiais em seus neurônios característicos. Essas unidades são popularmente conhecidas como portões (*gates*) (ZHANG *et al.*, 2019).

Os portões de uma LSTM permitem que a rede neural ajuste assertivamente os seus pesos sinápticos, ao mesmo tempo em que trunca o gradiente quando as informações não são mais necessárias. Tal procedimento simboliza uma forma de esquecimento por parte da LSTM, que evita o cancelamento de certas partes do seu processo de treinamento (SANTANA *et al.*, 2018).

Como toda arquitetura RNN, as redes LSTMs possuem a capacidade de memorizar algumas informações dos seus estados anteriores ao longo do tempo (LE *et al.*, 2019). No entanto, deve-se notar que a arquitetura LSTM consegue não apenas memorizar, mas também controlar o tempo em que estas informações permanecem durante o processo de treinamento, conseguindo criar um mecanismo de memória de longo prazo muito mais eficiente que uma RNN normal (WOLLMER *et al.*, 2013; LE *et al.*, 2019). Esse atributo é obtido através de um dos portões dos neurônios LSTM, o chamado *forget gate*.

Em geral, os neurônios (também conhecidos como células ou blocos de memória) de uma rede LSTM são compostos individualmente por 3 portões, que são eles: o portão de esquecimento (*forget gate*), o portão de entrada (*input gate*) e o portão de saída (*output gate*) (LI *et al.*, 2018). Todos eles possuem uma função de ativação para controlar as informações que fluem em cada sentido da célula (SANTANA *et al.*, 2018), possibilitando sua esquematização de acordo com a Figura 5.4,

Figura 5.4 – Esquematização de uma célula LSTM.



Fonte: Adaptado de Le *et al.* (2019).

Conforme mencionado, o *forget gate* controla quais informações serão mantidas pela célula LSTM, sendo, conseqüentemente, também responsável por eliminar as informações desnecessárias de estados anteriores, o que contribui para o processo de aprendizado da rede (SANTANA *et al.*, 2018; LE *et al.*, 2019). Para esse fim, três entradas são apresentadas à unidade, que são elas: um vetor de entrada atual ( $x_t$ ), um vetor de estado anterior ( $s_{t-1}$ ) e um vetor de saída da célula anterior ( $y_{t-1}$ ). A partir daí, cada vetor é multiplicado pela sua respectiva matriz de peso e acrescentado ao *bias* (YAN, 2016).

Após o cálculo de propagação usual dentro do *forget gate*, o resultado é então passado através de uma função de ativação binária ( $\varphi_0$ ), onde a saída 0 representa um processo de esquecimento dos dados avaliados e a saída 1 representa a retidão das informações para uso futuro (SANTANA *et al.*, 2018).

O portão de entrada (*input gate*), por outro lado, é responsável por atualizar a célula LSTM no momento atual, sendo esse procedimento baseado nos valores de entrada da célula no instante de tempo  $t$  e no seu estado anterior  $s_{t-1}$  (mensurado pelo portão *forget gate*) (BISPO, 2018; LI *et al.*, 2018). Dessa forma, o fluxo de informação dentro desta unidade é controlado de acordo com a equação (5.3),

$$s_t = \varphi_0(W_0 \cdot [y_{t-1}, x_t] + b) \cdot (s_{t-1} + \varphi_1(W_1 \cdot [y_{t-1}, x_t] + b)) \quad (5.3)$$

onde  $\varphi_0$  e  $\varphi_1$  geralmente são funções não lineares e  $W_i$  são matrizes de pesos avaliadas em cada parte da estrutura da célula. Na literatura, as funções *Sigmoide* e *TanH* são comumente usadas para representar os componentes  $\varphi_0$  e  $\varphi_1$ , respectivamente (BISPO, 2018; LI *et al.*, 2018).

A saída ( $y_t$ ) da célula LSTM é obtida por meio do *output gate*, o qual utiliza-se de uma função *sigmoidal* para determinar quais dos valores de estado serão lembrados para a mensuração de sua resposta final. Estes valores, são então multiplicados a um reajuste (exercido pela aplicação de uma função *TanH* sobre o estado da célula  $s_t$ ), de forma a gerar a saída para a próxima célula (ZHAO, 2016).

Uma rede neural de memória a longo prazo é composta de várias células de processamento, que são dispostas em camadas para formar a arquitetura LSTM (BISPO, 2018; LI *et al.*, 2018). Esse modelo de rede neural tem sido amplamente aplicado nos últimos anos, principalmente no tratamento da linguagem natural e na análise de séries temporais (BALDI *et al.*, 2000; ECK; SCHMIDHUBER, 2002; GERS; ECK; SCHMIDHUBER, 2002; GRAVES *et al.*, 2008; SUTSKEVER; MARTENS; HINTON, 2011; RAO; SPASOJEVIC, 2016; NOWAK; TASPINAR; SCHERER, 2017; BISPO, 2018; PAWADE *et al.*, 2018; SIAMI-NAMINI; TAVAKOLI; NAMIN, 2018; SUBRAMANIAN *et al.*, 2018; WANG *et al.*, 2018; LUAN; LIN, 2019; ELSWORTH; GÜTTEL, 2020; KAREVAN; SUYKENS, 2020; SANTHANAM, 2020). No entanto, estudos adicionais sobre a aplicabilidade dessa arquitetura no monitoramento da integridade estrutural ainda se fazem necessários.

## Capítulo 6

---

# Modelagem Computacional de Técnicas de Aprendizagem Profunda Aplicadas ao Monitoramento de Integridade Estrutural

---

Esta contribuição se concentrará na implementação de redes neurais convolucionais e redes LSTM através do uso do pacote *Keras*, interno à biblioteca *Tensorflow*, que permite à construção e a manipulação de camadas neurais em forma de pilha, facilitando a sua implementação e fluxo de processamento.

Assim, o presente capítulo aborda uma modelagem introdutória dessas arquiteturas em apoio ao método de SHM por impedância eletromecânica, pontuando os principais componentes utilizados e os recursos necessários.

Com o auxílio da arquitetura CNN, uma tarefa de classificação binária de danos será empregada em vigas de alumínio, analisando a sensibilidade da combinação desta rede neural com a técnica de impedância em relação as alterações ambientais da etapa de aquisição de dados. Quanto a arquitetura LSTM, esta será empregada para se realizar a previsão do nível de corrosão em vigas de aço, mediante o desgaste por ácido clorídrico, auxiliando também o diagnóstico de vida estrutural deste tipo de sistema.

A modelagem empregada em cada arquitetura, entretanto, caracteriza-se por ser simplificada, uma vez que servirá apenas para subsidiar um contexto de aplicação para os demais experimentos que serão detalhados no capítulo posterior.

### 6.1 *Tensorflow*

O *Tensorflow* é uma biblioteca de código aberto, escrita em *python*, que foi lançada em 2015 pela equipe do *Google Brain Research Group*, para estudos de *machine learning*

e redes neurais profundas (GOLDSBOROUGH, 2016; AGARWAL, 2018). Seu principal diferencial está na maneira como os dados são processados, pois os cálculos são realizados na forma de grafo orientado (RAMPASEK; GOLDENBERG, 2016).

Nesse sentido, os vértices do grafo representam as operações matemáticas e as arestas representam os tensores (matrizes de dados multidimensionais) que fluem entre as suas respectivas operações numéricas (FERRI, 2016; ALBOY, 2019).

Além disso, como vantagem do *tensorflow*, pode-se citar o fato dele ser executável em uma ou mais unidades CPUs e/ou GPUs, o que expande significativamente a sua gama de aplicações (ROUHANI, 2019; TENSORFLOW, 2020).

## 6.2 Exemplificação da Implementação Computacional de uma CNN para à Detecção de Danos Estruturais em Assinaturas de Impedância Eletromecânica

### 6.2.1 Procedimento Experimental

A fim de facilitar o entendimento da implementação de uma CNN em linguagem *python*, e já introduzindo-a em um contexto de monitoramento da integridade estrutural, toma-se como exemplo a classificação das assinaturas de impedância eletromecânica de 3 vigas de alumínio geometricamente idênticas ( $500 \times 38 \times 3.2\text{mm}$ ).

Para tanto, cada uma das estruturas utilizadas foi monitorada em duas diferentes condições de integridade (com dano e sem dano) e em 3 temperaturas de aquisição ( $0^\circ\text{C}$ ,  $10^\circ\text{C}$  e  $20^\circ\text{C}$ ). Assim, o condicionamento experimental aqui adotado objetiva verificar a capacidade de detecção de danos em estruturas sujeitas a variação de temperatura, fazendo-se uso da arquitetura CNN.

A aquisição das assinaturas de impedância foi realizada por intermédio de um transdutor PZT ( $20\text{mm}$  de diâmetro por  $1\text{mm}$  de espessura) acoplado à  $100\text{mm}$  de distância de uma das extremidades de cada estrutura analisada. Já a forma da simulação do dano se deu pela a adição de massa aos 3 sistemas estruturais (3 porcas variando de  $0.6 - 2.2\text{g}$  coladas à  $380\text{mm}$  de distância do adesivo PZT). A Figura 6.1a e 6.1b apresentam, respectivamente, as 3 vigas de alumínio utilizadas e as condições de dano a elas impostas.

Para que se pudesse devidamente analisar as estruturas, essas foram submetidas a uma condição de contorno (apoio simples) na qual espumas de poliestireno foram utilizadas a fim de minimizar a influência de ruídos durante a fase de aquisição.

Alterações nas condições ambientais durante o processo de aquisição podem provocar pequenas modificações nas assinaturas de impedância eletromecânica. Dessa forma,

na literatura, esforços têm sido realizados a fim de minimizar possíveis erros no prognóstico estrutural (AFSHARI, 2012; RABELO *et al.*, 2017a; RABELO *et al.*, 2017b; TSURUTA *et al.*, 2017).

Figura 6.1 – Estruturas utilizadas como objeto de estudo.

(a) Sistema Estruturais (Vigas de Alumínio + Pastilha PZTs).



(b) Condições de dano por adição de massa.



Fonte: O autor (2021).

Nesta investigação, para que se pudesse delimitar e controlar os 3 diferentes níveis de temperatura foi utilizada uma câmara climática da série *Platinous EPL-4H*, que se encontra disponível no laboratório LMest do curso de Engenharia Mecânica da Universidade Federal de Uberlândia. A Figura 6.2 apresenta graficamente o modelo da câmara climática utilizada neste trabalho.

Figura 6.2 – Câmara Climática *Platinous EPL-4H*.



Fonte: O autor (2021).

As câmaras climáticas da série *Platinous EPL-4H* são baseadas no BTHC (*Balanced Temperature and Humidity Control*), que emprega uma balança termodinâmica para o seu

controle dos parâmetros de temperatura. O volume operacional do modelo utilizado é de aproximadamente 900L ( $\approx 100 \times 100 \times 90 \text{cm}$ ) e possui a capacidade de controle da temperatura para um range de  $-35^\circ\text{C}$  a  $180^\circ\text{C}$ .

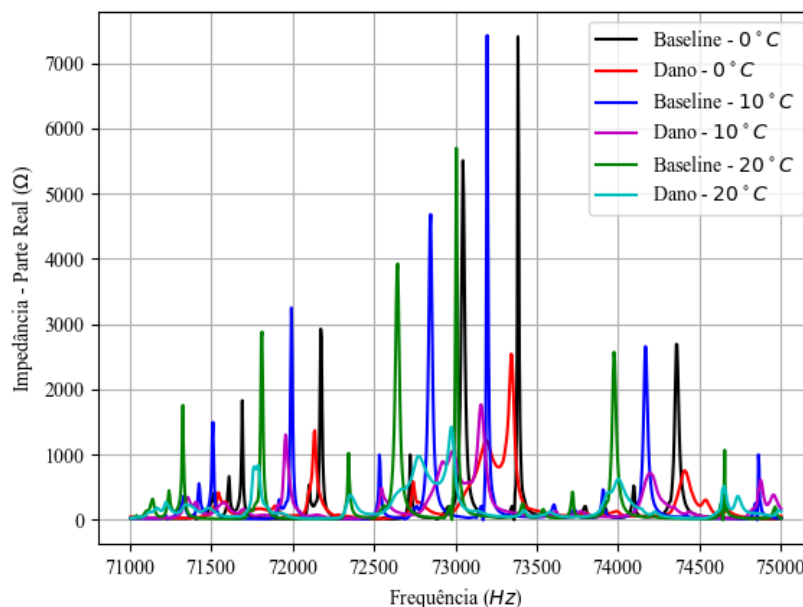
Já para a construção, treinamento e validação do modelo CNN foram coletadas ao todo 20 assinaturas de impedância eletromecânica para o estado de baseline (condição íntegra da estrutura) e 80 assinaturas para o estado danificado, totalizando assim em um montante de 900 amostras para avaliação (300 referentes a cada uma das vigas).

O range de frequência empregado na aquisição das assinaturas de impedância foi de  $68 - 77 \text{kHz}$  com passo de  $4.5 \text{Hz}$  e um total de 2000 pontos amostrais. Vale ressaltar ainda, que a faixa de frequência utilizada foi escolhida por meio de um processo de tentativa e erro, a fim de subsidiar um predomínio para o método de otimização por busca aleatória.

Objetivando delimitar a melhor faixa de varredura para a identificação da presença de danos, dentre a parcela de frequência pré-escolhida, o método de otimização por busca aleatória foi aplicado ao conjunto das assinaturas de impedância eletromecânica. Tal procedimento, tomou-se por base a metodologia imposta por Bento *et al.* (2017), que se utiliza da métrica de dano RMSD (Seção 2.4.1) como comparativo da melhor faixa de frequência a ser monitorada.

Assim, com a aplicação do método de otimização por busca aleatória, a faixa de frequência escolhida passou a ser de  $71 \text{kHz}$  à  $75 \text{kHz}$  com um total de 888 pontos amostrais. As médias das assinaturas de impedância podem ser observadas na Figura 6.3.

Figura 6.3 – Médias das assinaturas de impedância de cada grupo avaliado.



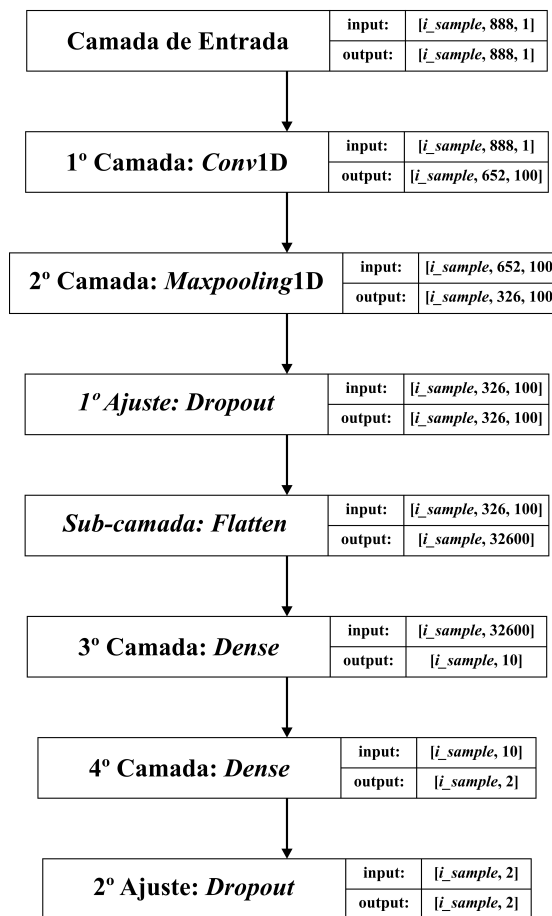
Fonte: O autor (2021).

### 6.2.2 Construção dos Modelos CNNs

No intuito de delimitar a melhor arquitetura CNN para o problema em questão, inicialmente deve-se identificar o tipo e as dimensões dos dados de entrada que serão utilizados na rede. Assinaturas de impedância eletromecânica são vetores bidimensionais, onde se tem os sinais de impedância eletromecânica no domínio da frequência. Tal fenômeno pode ser modelado, desta forma, por uma 2D CNN através do uso de seus dois parâmetros. No entanto, se considerarmos um range de frequência padronizado à todas as amostras avaliadas, uma outra abordagem unidimensional poderá ainda ser realizada, utilizando-se para isso apenas os valores da impedância medida no transdutor.

Neste trabalho, em razão das amostras consideradas serem medidas no mesmo range de frequência (71 – 75 kHz), será empregado uma análise unidimensional das assinaturas de impedância eletromecânica utilizando uma arquitetura 1D CNN de 4 camadas. Desse modo, a topologia usada será composta por uma camada convolucional, uma camada *pooling* (do tipo *MaxPooling*) e duas camadas totalmente conectadas, conforme é apresentado na Figura 6.4.

Figura 6.4 – Arquitetura neural convolucional implementada no experimento.



Fonte: O autor (2021).

Convém destacar na Figura 6.4, que os passos denominados por “1º Ajuste”, “Subca-

*mada*” e “2º Ajuste” não foram inclusos à contagem das camadas utilizadas, visto que estes, por sua finalidade, aplicam apenas um pré-ajuste no conjunto de pesos sinápticos (GULGEC; TAKÁČ; PAKZAD, 2017). Além disso, a dimensão *i\_sample* representa o tamanho do lote de amostras avaliado durante a iteração *i* da fase de treinamento (embora cada uma dessas amostras seja processada separadamente para ajustar os pesos sinápticos da rede).

Para se inicializar a construção do modelo de rede neural convolucional no *python*, deve-se inicialmente importar a biblioteca *Tensorflow* para a memória do sistema e, subsequentemente, estanciar e empilhar a primeira camada (entrada) do modelo CNN. Esse processo pode ser realizado por meio da execução dos comandos abaixo:

```
>> import tensorflow as tf
>> entrada = tf.keras.layers.Input(shape=(888,1))
```

Nesta contribuição foram empregados todos pontos amostrais das assinaturas de impedância eletromecânica. Dessa forma, o sistema de inferência desenvolvido passa a agregar mais graus de liberdade, o que proporciona maior confiabilidade ao método classificatório.

Para que pudesse ser introduzida toda a extensão das assinaturas de impedância no modelo CNN, foi implementado uma camada de entrada com 888 neurônios. Assim, cada ponto amostral possui seu respectivo neurônio de entrada, possibilitando a convolução entre as assinaturas de impedância eletromecânica e os filtros de abstração.

Como passo seguinte a construção da camada de entrada, deve-se empilhar alternadamente as demais camadas convolucionais e *pooling* ao modelo CNN, de modo a elaborar a arquitetura de rede a ser desenvolvida.

Ao todo existem três tipos de camadas convolucionais previamente implementadas no pacote *Keras*, que são elas: a *Conv1D*, a *Conv2D* e a *Conv3D*. Todavia, todos os tipos de camadas convolucionais executam as mesmas funções e processos matemáticos, diferenciando-se apenas no número de dimensões em que se é convoluido os dados (CHOLLET, 2017).

Conforme mencionado, será aplicado apenas uma análise unidimensional nas assinaturas de impedância eletromecânica. Logo, para a implementação da rede foi utilizada uma camada convolucional 1D com 100 filtros de abstração, onde cada filtro possuía uma dimensão de 237 pesos sinápticos escolhidos aleatoriamente.

A implementação da camada convolucional desenvolvida nesta seção obedeceu a seguinte formulação do *Tensorflow* no IDE do *python*:

```
>> rede_cnn = tf.keras.layers.Conv1D(filters=100,
                                     kernel_size=237,
                                     strides=1,
                                     padding='valid',
```

```
use_bias=True,  
activation='relu')(entrada)
```

onde os parâmetros fornecidos a função são, respectivamente, o número de filtros utilizados para convolução, o comprimento do *kernel* de abstração, o deslocamento linear do *kernel*, o tipo de *padding*, a utilização de *bias* na camada convolucional e a função de ativação utilizada.

Para o processo de convolução, o deslocamento entre os *kernels* de abstração e os dados de entrada foi atribuído como passo 1, de modo a avaliar todos os possíveis pontos amostrais. No entanto, não foi atribuído a ação de *padding* ('*valid*'), visto que os dados de extremos das assinaturas utilizadas já eram nulos.

Após ter sido realizado todas as convoluções dos sinais de entrada pela camada convolucional, foi aplicado nos seus *feature maps* uma função de ativação do tipo *ReLU*. O emprego dessa função tem por objetivo a normalização dos resultados de cada *feature map*, possibilitando assim apenas a propagação dos valores positivos dos dados de saída da camada antecessora.

Vale ressaltar que todos os parâmetros empregados na modelagem da camada convolucional foram escolhidos de forma a analisar uma melhor parcela dos sinais utilizados, sendo esses dependentes especificamente de cada caso sob investigação.

Ainda, devido a aplicação dos parâmetros anteriormente citados, pode-se observar na Figura 6.4 uma redução de 26% na quantidade de dados a serem avaliados pela camada *pooling*. Tal paradigma contribui não apenas para o seu custo computacional, mas também auxilia na abstração e separabilidade dos dados pelo método classificatório (WANG *et al.*, 2019).

Conforme a Seção 4.2.2, o acoplamento de uma camada de subamostragem a um modelo CNN é, principalmente, dependente quanto ao tipo de função a ser imposta por essa mesma camada, sendo ela variante entre o valor máximo ou médio de cada sub-região do *feature map*.

Neste trabalho, a camada *pooling* adotada no modelo CNN empregou somente filtros de ordem 2 na abstração das características de impedância, sendo mantido somente o maior valor alcançado para cada uma das áreas analisadas do *feature map*. Desta maneira, para as camadas consecutivas, apenas 50% dos dados de entrada da camada *pooling* serão propagados.

A função do *python* utilizada para o acoplamento da camada *pooling* no modelo CNN é dada conforme seguir:

```
>> rede_cnn = tf.keras.layers.MaxPool1D(pool_size=2)(rede_cnn)
```

onde o único parâmetro fornecido a função é a dimensionalidade da janela de inspeção, a qual é correspondente ao tamanho da sub-região do *feature map* a ser avaliada.

Já para se acoplar as camadas totalmente interligadas ao modelo CNN, foi implementada duas outras subcamadas de ajuste, sendo uma de *dropout* e a outra de *flatten*. Tal aplicação, visa ajustar computacionalmente os dados de resposta da camada *pooling*, para que assim os mesmos sejam utilizados como entrada do modelo *feedforward*.

Devido a dimensionalidade dos dados de saída da camada *pooling* ser significativa, foi adicionado ao modelo classificatório duas camadas totalmente conectadas. A primeira camada do tipo densa foi implementada com dez neurônios, de modo a possibilitar uma redução nos parâmetros ajustáveis da última camada.

A arquitetura CNN implementada nesta contribuição tem por finalidade catalogar as assinaturas de impedância em dois estados, com dano e sem dano. Dessa forma, a camada de resposta do modelo passa a possuir apenas dois neurônios, dos quais suas saídas representam a probabilidade de pertencerem, respectivamente, as classes com dano (ativação do segundo neurônio) e sem dano (ativação do primeiro neurônio).

Para que a camada de saída responda a probabilidade de cada amostra pertencer a um determinado grupo foi utilizada nas camadas totalmente conectadas a função logística *Softmax*. Essa função realiza a distribuição dos dados de entrada, classificando-os quanto a sua similaridade com cada uma das classes alvo pré-delimitadas (CHOLLET, 2017). Dessa forma, a configuração dos parâmetros utilizados para se implementar as camadas totalmente conectadas é dada conforme a seguir:

```
>> rede_cnn = tf.keras.layers.Dropout(0.2)(rede_cnn)
>> rede_cnn = tf.keras.layers.Flatten()(rede_cnn)
>> rede_cnn = tf.keras.layers.Dense(units=10,
                                     activation='softmax')
                                     (rede_cnn)
>> rede_cnn = tf.keras.layers.Dense(units=2,
                                     activation='softmax')
                                     (rede_cnn)
```

Após a topologia neural ser desenvolvida, deve-se realizar o armazenamento e a construção do modelo CNN com os parâmetros de otimização e ajuste dos pesos sinápticos. Tais parâmetros definem o modo como o algoritmo de treinamento acessará e regulará os atributos livres do modelo implementado, além de delimitar qual será a função de perda utilizada para a identificação do erro absorvido pela rede.

Para se realizar a construção de um modelo CNN, por meio da biblioteca *Tensorflow*, deve-se digitar os seguintes comandos no IDE do *python*:

```
>> model = tf.keras.models.Model(entrada, rede_cnn)
>> otimizador = tf.keras.optimizers.RMSprop(learning_rate=0.001,
                                             rho=0.8)
>> loss_function = tf.keras.losses.BinaryCrossentropy()
>> model.compile(optimizer=otimizador,
                 loss=loss_function,
                 metrics=['accuracy'])
```

A função “*Model*” efetua o sequenciamento e a construção das camadas neurais que compõem a rede, sendo esse processo baseado nos tensores pré-definidos. Já a função “*Compile*” realiza a configuração dos processos de treinamento e aprendizagem da arquitetura neural, sendo delimitado a função de perda e o método de otimização conforme os parâmetros a ela fornecidos.

Neste experimento, é utilizado a função de perda *Binary Crossentropy* e o método de otimização *RMSprop* (*Probabilistic Root Mean Square*), visto que estes exibem uma boa eficiência em problemas de classificação (GULGEC; TAKÁČ; PAKZAD, 2019). Ainda, convém destacar nesta seção que a taxa de aprendizado ( $\eta$ ) e o fator de decaimento do gradiente ( $\rho$ ) foram definidos mediante a realização de experimentos prévios, visto que estes influenciam diretamente na performance do processo de treinamento neural (CHOLLET, 2017).

Após ser executado todo o processo de construção e configuração do modelo CNN, parte-se para a etapa de treinamento e aprendizado da rede, na qual o modelo é ajustado de acordo com as amostras de treinamento e valores alvos a ele fornecidos. Para se realizar o treinamento de uma CNN no *python*, usa-se a função *fit*, conforme é apresentado a seguir:

```
>> history = CNN.fit(amostras_treinamento,
                    target_treinamento,
                    batch_size=2,
                    epochs=40)
```

Nessa função também é passado a quantidade de amostras utilizadas para à atualização dos pesos sinápticos (*batch size*) e o total de épocas (*epochs*) para treinamento. Todo esse histórico processual, é então armazenado em uma estrutura de dados a fim de propiciar análises posteriores, tais como a verificação da curva de aprendizado e a medição da acurácia obtida.

Destaca-se que um modelo CNN foi construído e treinado para cada estrutura de viga individualmente, a fim de possibilitar a previsão de danos estruturais. Dessa forma, das 300 assinaturas de impedância para cada modelo, foram removidas 30 amostras aleatórias para testes e as 270 amostras remanescentes foram consideradas para treinar e construir o modelo anteriormente descrito.

### 6.2.3 Resultados e Conclusões Prévias da Implementação

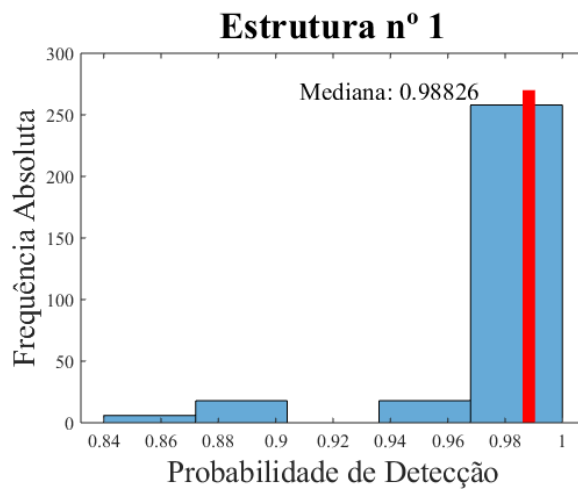
Conforme citado, durante o processo de treinamento, foi utilizada a função de perda *Binary Crossentropy* para verificar a precisão de resposta das redes. Todos os modelos alcançaram uma função de perda de cerca de 0.221, representando uma pequena diferença entre o resultado e os grupos-alvo, relacionados à complexidade do problema.

Posteriormente, o algoritmo de otimização RMSprop calculou os pesos ajustados de cada rede. As precisões obtidas no final desta etapa foram de aproximadamente 85.74%, 89.40% e 95% para as estruturas de viga  $n^{\circ}1$ ,  $n^{\circ}2$  e  $n^{\circ}3$ , respectivamente.


Depois que os pesos foram ajustados, as redes treinadas foram avaliadas pelo uso das amostras de teste como entrada dos modelos. Assim, cada modelo contou com 10 execuções para todas as 30 amostras em lote. Como resultado, todos os três modelos obtiveram diferentes graus de probabilidade de detecção de danos. A Figura 6.5a, 6.5b e 6.5c apresenta um histograma de todos os testes realizados.

Figura 6.5 – Histograma com os resultados dos testes impostos a cada modelo.


(a) Resultado dos testes para a estrutura  $n^{\circ}1$ .



(b) Resultado dos testes para a estrutura  $n^{\circ}2$ .



(c) Resultado dos testes para a estrutura n°2.



Fonte: O autor (2021).

De acordo com a Figura 6.5a, a probabilidade de detecção de danos pelo primeiro modelo CNN (estrutura n°1) varia de 84% a 100%. Este gráfico inclui todas as condições de integridade avaliadas (*baseline* e dano) no teste. Dado que a distribuição dos resultados claramente não segue uma distribuição normal, avalia-se a sua mediana (que é um melhor parâmetro para comparação de grupos), cuja qual atingiu um valor de 98.83%.

A Figura 6.5b ilustra o histograma para o modelo da estrutura n°2, sendo que resultados semelhantes foram obtidos para o segundo modelo, com uma probabilidade de detecção de danos de 81% a 100%, com uma mediana de 97.49%. Finalmente, o último histograma apresenta a probabilidade de detecção de danos para o terceiro modelo (estrutura n°3), variando de 81% a 100%, com mediana de 97.44%.

Nessa avaliação inicial todos os modelos CNNs desenvolvidos atingiram uma probabilidade de detecção de danos maior que 97%, significando uma boa capacidade de classificação de danos para as três estruturas utilizadas. Assim, vale ressaltar que, embora o modelo empregado nesta contribuição seja simples (composto por apenas uma camada convolucional e *pooling*), os resultados alcançados são favoráveis à aplicação desta técnica de *machine learning* no método SHM por impedância eletromecânica.

Ainda, uma vez que a temperatura ambiente é muito relevante para a técnica SHM baseada em impedância, mudando as amplitudes de suas assinaturas de impedância eletromecânica, esse resultado específico demonstra a capacidade dos modelos em separar danos e assinaturas primitivas, independentemente da temperatura, sendo muito relevante para a metodologia proposta.

## 6.3 Exemplificação da Implementação Computacional de uma rede LSTM para a Previsão da Severidade de Danos Estruturais em Vigas de Aço Sob Ação Corrosiva

### 6.3.1 Procedimento Experimental


Para se executar o processo de implementação de uma rede LSTM em linguagem *python*, duas vigas de aço geometricamente idênticas ( $300 \times 50 \times 3.2\text{mm}$ ) foram consideradas sob ação corrosiva controlada. Essa condição experimental foi formulada com o objetivo de se verificar alterações nas assinaturas de impedância, resultantes ao processo de corrosão das estruturas, analisando-se a progressão de severidade nas mesmas.

Assim, a elaboração experimental aqui adotada objetiva verificar a capacidade de previsão da magnitude de falhas estruturais em vigas de aço sujeitas a corrosão por ácido clorídrico (HCL), fazendo-se uso da arquitetura LSTM.

A aquisição das assinaturas de impedância foi realizada por intermédio de um transdutor PZT ( $30\text{mm}$  de diâmetro por  $2\text{mm}$  de espessura) acoplado a  $50\text{mm}$  de distância de uma das extremidades de cada estrutura analisada.

Para se avaliar adequadamente as duas vigas de aço sob condições similares de corrosão, todas as medições ocorreram com os corpos de prova na forma bi-apoiada, sendo delimitado regiões contornadas (berços) para a aplicação, subsequente, de ácido em cada uma das estruturas separadamente. A Figura 6.6 mostra as vigas usadas no procedimento experimental adotado nesta seção.

Figura 6.6 – Vigas de aço utilizadas no experimento de corrosão por HCL.



Fonte: O autor (2021).

A região (berço) de aplicação do HCL, em cada estrutura, foi definida com uma dimensão de  $32\text{mm}$  de largura por  $44\text{mm}$  de comprimento, posicionada à  $150\text{mm}$  de distância do seu respectivo adesivo PZT. A concentração do ácido utilizado é de 36.5%, sendo que a aplicação do mesmo em cada estrutura foi realizada por meio de gotejamento, o que

permitiu uma melhor otimização do processo de aquisição, em relação a outras formas de aplicação presentes na literatura, como a aplicação por névoa corrosiva.

A ordem de coleta das assinaturas de impedância e aplicação do ácido HCL nas estruturas monitoradas foi definida de acordo com o Quadro 6.1, na qual foram coletadas 30 medições das assinaturas de impedância para cada conjunto de severidade avaliado, totalizando assim um montante de 240 amostras (120 referentes a cada uma das vigas) para a construção do modelo neural.

Medição	Aplicação do Ácido HCL	Estado de Integridade Avaliado
#1	–	<i>Baseline</i>
	Sim	
#2	-	Dano #1 (24h após 1º Aplicação)
	Sim	
#3	–	Dano #2 (24h após 2º Aplicação)
#4	–	Dano #3 (48h após 2º Aplicação)

Fonte: O autor (2021).

Quadro 6.1 – Sequenciamento das coletas e grupos de integridade avaliado na implementação do experimento.

As assinaturas de impedância foram monitoradas em uma faixa de frequência de 30 – 100kHz, com passo de 10.02Hz e um total de 6980 pontos amostrais, cada um dos quais sendo calculado com referência a 512 médias.

Ao todo, foram considerados 4 níveis de integridade das estruturas avaliadas, que são eles: uma condição íntegra das vigas de aço (*baseline*) e três outras condições após a corrosão parcial do material pela aplicação do ácido HCL.

Todos os experimentos com os corpos de prova foram realizados em ambiente enclausurado por grades, mas sujeito ao ambiente externo, propiciando variações de temperatura e umidade nas vigas monitoradas. Tal formulação foi realizada para se aproximar os testes experimentais das condições reais de operação desse tipo de estrutura. Dessa forma, deve-se notar que as alterações nas assinaturas de impedância avaliadas podem depender tanto das características do processo progressivo de corrosão quanto das condições ambientais (temperatura e ruído) da fase de aquisição.

Assim, para minimizar os efeitos da variação de temperatura nas assinaturas de impedância, foi aplicado um algoritmo de compensação da temperatura conhecido como *Método do Deslocamento Efetivo em Frequência por Análise de Correlação*, o qual realiza pequenos ajustes (horizontais e verticais) nas assinaturas de impedância, a fim de maximizar o coeficiente de correlação entre os grupos de sinais avaliados (RABELO *et al.*, 2017a).

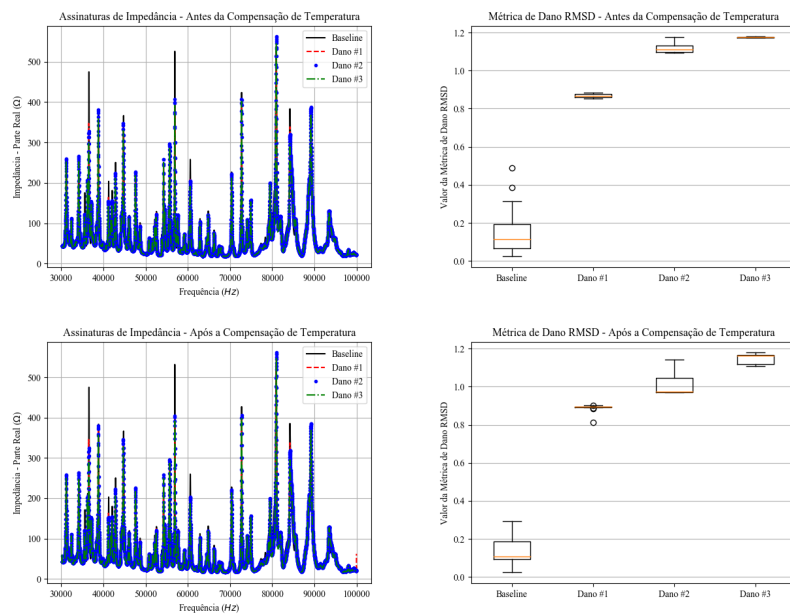
Após compensar os efeitos da variação de temperatura nas assinaturas de impedância, a métrica de dano RMSD (equação 2.9) foi implementada para uso posterior na cons-

trução do modelo neural LSTM. Esse índice métrico foi utilizado como entrada no modelo neural, pois fornece uma melhor identificação da progressão de severidade do dano, além de permitir a aplicação mútua das técnicas de atraso e recorrência.

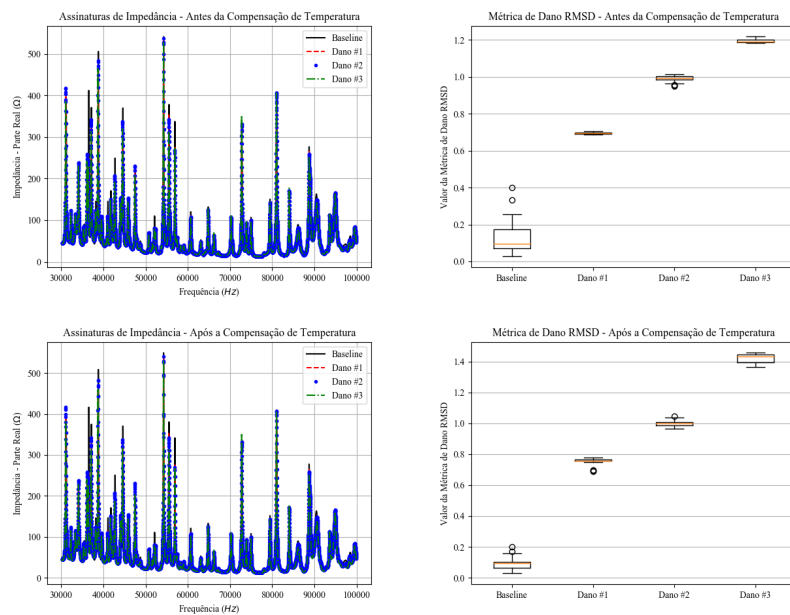
As Figuras 6.7a e 6.7b mostram as assinaturas de impedância e os grupos de índices métricos antes e depois da compensação de temperatura.

Figura 6.7 – Médias das assinaturas de impedância de cada nível de severidade e seus respectivos valores de métrica RMSD.

(a) Estrutura  $n^{\circ}1$ .



(b) Estrutura  $n^{\circ}2$ .



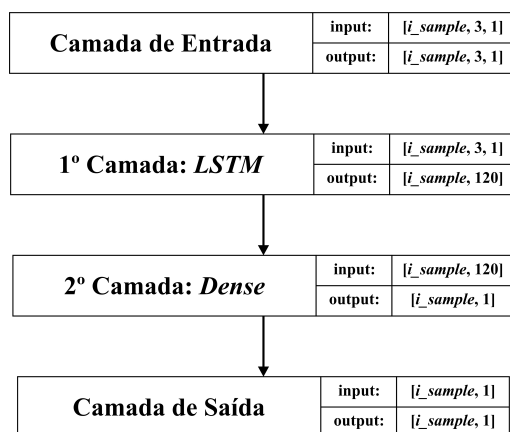
Fonte: O autor (2021).

### 6.3.2 Construção do Modelo LSTM

Nesta contribuição, um modelo LSTM de duas camadas (Figura 6.8) será utilizado para prever a severidade da corrosão nas estruturas monitoradas, usando apenas os valores da métrica de dano RMSD como entrada do modelo neural.

O emprego desta formulação decorre do fato de que, em problemas de corrosão, o nível de severidade estrutural obtido pelo cálculo das métricas de dano tende a aumentar ao longo do tempo, possibilitando o uso de tais valores na modelagem do fenômeno. Assim, diante do exposto, a arquitetura neural utilizada será composta por apenas uma camada LSTM e uma camada totalmente conectada, sendo está expressa de acordo com a Figura 3.

Figura 6.8 – Arquitetura neural LSTM implementada no experimento.



Fonte: O autor (2021).

Conforme destacado por [Millstein \(2018\)](#), a modelagem de uma rede neural usando o pacote *Keras* é realizada através do sequenciamento de camadas tensoriais, em que funções protótipos são empilhadas a fim de se construir a arquitetura neural. Assim, a modelagem usada neste estudo de caso seguiu a mesma formulação apresentada na Seção 6.2.2, para as camadas de entrada e totalmente conectada, variando apenas os seus respectivos parâmetros de implementação.

Já para a realização do processo de recorrência, foi utilizada uma camada LSTM com 120 núcleos de memória, na qual as suas funções de ativação  $\varphi_0$  (ativação da célula) e  $\varphi_1$  (função de recorrência) foram definidas de acordo com o seguinte comando:

```
>> rede_cnn = tf.keras.layers.LSTM(units=120,
                                   activation='tanh',
                                   recurrent_activation='sigmoid',
                                   use_bias=True)
```

Em decorrência do presente estudo de caso ser avaliado como um problema de regressão, a função de perda *RMSE* e o método de otimização conhecido como *Adam* foram utilizados para configurar o modelo neural, pois apresentam uma melhor eficiência quando comparados a outros métodos e funções disponíveis ([GULLI; PAL, 2017](#)).

Também vale destacar que, como na Seção 6.2, um modelo LSTM foi construído e treinado para cada estrutura de viga separadamente, visando-se validar a metodologia imposta nesta contribuição. Assim, dos 120 valores métricos de cada modelo, 48 amostras sequenciais foram removidas para teste e as 72 amostras remanescentes foram consideradas para treinar e construir o modelo neural anteriormente descrito.

Ainda, vale ressaltar que tanto a técnica de atraso quanto a de recorrência (fornecida pela formulação do modelo LSTM) foram aplicadas, conjuntamente, ao grupo de dados avaliado. Entretanto, para se introduzir a técnica de atraso no presente processo experimental, foi necessário que cada ponto de previsão utilizasse suas respectivas unidades anteriores da série, o que causou uma redução do número de pontos a serem incorporados na construção do modelo.

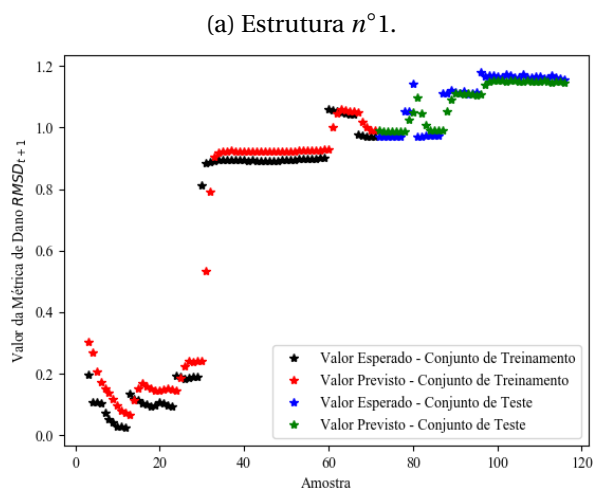
Assim, considerando um nível de atraso  $j = 3$ , o número final de pontos a serem utilizados no modelo são, respectivamente, 45 valores para teste e 69 amostras para treinamento da rede.

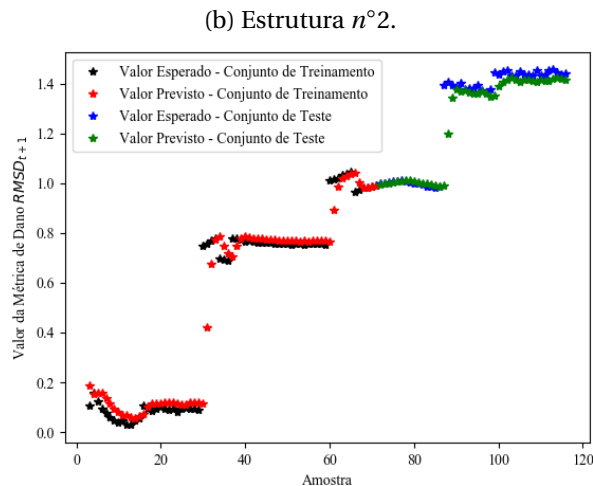
### 6.3.3 Resultados e Conclusões Prévia da Implementação

Conforme mencionado, durante o processo de treinamento, a função *RMSE* foi utilizada para verificar a precisão de resposta das redes. Todos os modelos alcançaram uma função de perda de cerca de 0.0109, representando uma pequena diferença entre o resultado esperado e os valores-alvo, relacionados à complexidade do problema.

Posteriormente ao cálculo do erro, o algoritmo de otimização empregado (*Adam*) ajustou os pesos sinápticos de cada rede. A precisão obtida no final desta etapa foi de aproximadamente 90.42% e 90.22% para as estruturas de viga  $n^{\circ}1$  e  $n^{\circ}2$ , respectivamente.

Figura 6.9 – Relação entre os dados previstos pelos modelos neurais LSTM e os valores-alvo pré-delimitados.





Fonte: O autor (2021).

Após o ajuste dos parâmetros locais de cada modelo, as redes treinadas foram avaliadas pelo uso das amostras de teste como entrada dos modelos neurais. Como resultado, todos os modelos obtiveram diferentes graus de precisão na previsão da severidade estrutural de cada viga investigada.

As Figuras 6.9a e 6.9b mostram a comparação entre os resultados previstos e os valores reais de cada viga individualmente e, a partir delas, pode-se observar que a modelagem utilizada nesta contribuição conseguiu obter uma boa precisão em relação à previsão de severidade estrutural em vigas sujeitas a ação corrosiva por ácido clorídrico. Tal precisão atingiu um nível de 96.1% para os dados de teste do modelo  $n^{\circ}1$  e 92.68% para os dados de teste do modelo  $n^{\circ}2$ .

Assim, embora a arquitetura LSTM empregada nesta seção seja simples (composta por apenas uma camada recorrente), os resultados alcançados mostraram-se favoráveis à aplicação da técnica no método SHM por impedância eletromecânica.

## Capítulo 7

---

# Técnicas de *Deep Learning* Supervisionadas Aplicadas ao Monitoramento de Integridade Estrutural de um Sistema Rotativo

---

Em continuidade ao estudo da aplicabilidade das arquiteturas CNN e LSTM em suporte ao método de impedância eletromecânica para o monitoramento de integridade estrutural, duas novas abordagens experimentais são avaliadas no presente capítulo.

Em uma primeira instância (Seção 7.1), uma nova topologia convolucional será utilizada para se avaliar a integridade de um sistema rotativo, verificando a sensibilidade das CNNs quanto a um novo tipo de perturbação, que é a velocidade de operação da estrutura. Ademais, diferentemente da disposição empregada na Seção 6.2, o presente estudo de caso aplicará uma análise multiclasse do problema de detecção de danos, avaliando simultaneamente dois diferentes tipos de anomalia na operação do rotor.

Por outro lado, em um segundo momento (Seção 7.2), as assinaturas de impedância adquiridas neste mesmo procedimento experimental serão então reorganizadas, de forma a simular virtualmente algumas condições de manutenção, detecção de falhas e mudança habitual da velocidade de operação do rotor. Tal reestruturação do conjunto de dados visa construir uma série temporal característica do processo de inspeção desse tipo de sistema, possibilitando o emprego da arquitetura LSTM como método de predição da condição de integridade da estrutura avaliada.


Considerando a importância associada ao monitoramento de sistemas rotativos, seja por razões de segurança ou econômicas, a capacidade de identificar o estado de integridade estrutural desses sistemas, bem como a habilidade de prever sua necessidade de manutenção, torna-se de especial interesse em problemas de engenharia. Logo, os estudos de caso analisados neste capítulo visam contribuir para esse propósito.

## 7.1 Detecção de Anomalias em Sistemas Rotativos usando a Arquitetura CNN

### 7.1.1 Procedimento Experimental

Conforme observado no prefácio deste capítulo, um rotor sob diferentes condições de operação será utilizado como estrutura hospedeira, a fim de se detectar a presença de anomalias neste tipo de sistema. Para tanto, o método de impedância eletromecânica será empregado como forma de monitoramento e a arquitetura CNN como um estimador de condição de integridade estrutural. A Figura 7.1 mostra o sistema de rotor avaliado como objeto de estudo nesta seção.

Figura 7.1 – Sistema estrutural avaliado quanto a integridade estrutural sob diferentes condições de operação.




Fonte: Retirado de [Tsuruta et al. \(2017\)](#).

Pode-se observar que o sistema mecânico utilizado foi composto por um eixo de aço flexível (800mm de comprimento por 17mm de diâmetro), o qual é sustentado em certas posições latitudinais por meio de dois rolamentos de rolos cilíndricos e conectado, em uma de suas extremidades, a um motor DC de 0.5HP (Varimot© - modelo BN90M). A interação entre o motor elétrico e o eixo foi minimizada por meio de um acoplamento especial, chamado de *Lami-Torq* (GTG 402 × 100), da empresa Acoplast©.

Além disso, dois discos rígidos (150mm de diâmetro por 20mm de espessura) e uma polia de rotor de alumínio (140mm de diâmetro por 20mm de espessura) também foram acoplados ao sistema, para que condições de desbalanceamento do rotor pudessem ser simuladas a partir de tais componentes.

Já para a coleta das assinaturas de impedância, três sensores PZTs foram fixados ao eixo do rotor, utilizando-se de adesivo epóxi conforme mostrado na Figura 7.2. Por sua vez, cada um desses transdutores era composto por três pastilhas piezoelétricas (10mm de comprimento, 3mm de largura e 1mm espessura) que foram conectadas eletricamente em paralelo. No entanto, para o transdutor #2 uma configuração diferente foi adotada, acoplando quatro pastilhas PZTs em um único componente paralelo (Figura 7.2).

Figura 7.2 – Esquemática das dimensões e posicionamento dos transdutores piezoelétricos em relação aos componentes do rotor.




Fonte: Adaptado de Tsuruta *et al.* (2017).

A localização de cada transdutor, em relação aos demais componentes do rotor, pode ser observada também na Figura 7.2. Essa disposição foi formulada com base em resultados prévios da análise modal sobre o sistema mecânico a ser avaliado (TSURUTA *et al.*, 2017).

A Figura 7.3a mostra o anel deslizante (modelo *Michigan Scientific's S-Series Slip Ring* - C556019) que foi utilizado para conectar o sistema de aquisição (Figura 7.3b) a todos os sensores piezoelétricos. Tal anel é capaz de transferir sinais elétricos de peças estáticas para peças rotativas (e/ou vice-versa), com pouco nível de ruído e mesmo quando rotacionadas a uma alta velocidade de inspeção; tornando assim a configuração aqui adotada aplicável ao monitoramento de integridade estrutural de sistemas rotativos.

Figura 7.3 – Anel deslizante e sistema de aquisição empregados na coleta das assinaturas de impedância.



Fonte: Retirado de Tsuruta *et al.* (2017).


A faixa de frequência usada no método de impedância foi de 130 – 300kHz, com passo de 17Hz e um total de 10.000 pontos amostrais. Vale ressaltar ainda que essa faixa

de frequência foi escolhida com base na sua densidade de picos e com o objetivo de se detectar a presença de danos incipientes.

A presente seção visa verificar a capacidade de detecção de danos em um rotor sob diferentes condições operacionais. Dessa forma, foram avaliados quatro estados de integridade (*baseline*, danificado e 2 condições de desbalanceamento) da estrutura em estudo, cada um dos quais monitorado em até três velocidades (600rpm, 900rpm e 1200rpm) de operação.

Para o primeiro ensaio, foi verificada uma condição de falha da estrutura hospedeira, em que uma porca de aço (massa de 4.89g) foi fixada na superfície do eixo de aço flexível (Figura 7.4a). Em seguida, duas outras condições de desbalanceamento do rotor também foram monitoradas, adicionando-se massa a um dos discos rígidos (Disco  $n^{\circ}$  1) da estrutura, conforme mostrado nas Figuras 7.4b e 7.4c.

Figura 7.4 – Condições de dano simuladas sobre o rotor.



Fonte: Adaptado de Tsuruta *et al.* (2017).

O posicionamento dessas condições de perturbação em relação ao sistema de rotor pode ser verificado na Figura 7.2, onde *D#1* representa a localização da condição de dano, *Db#1* representa a localização da primeira condição de desequilíbrio e *Db#2* representa a localização da segunda condição de desequilíbrio, em que *Db#1* é igual a *Db#2*.

Para fins de simplificação, a Tabela 7.1 apresenta um resumo das configurações experimentais adotadas neste trabalho para a coleta das assinaturas de impedância eletromecânica. Em geral, 30 repetições dessas assinaturas (para cada condição de integridade estrutural) foram monitoradas na faixa de frequência especificada, totalizando assim em um montante de 360 sinais para avaliação.

As assinaturas de impedância monitoradas apresentaram um nível de ruído inerente ao próprio processo de coleta de dados, uma vez que a transmissão desses dados é baseada na transposição de um sistema rotativo para um sistema estático. Assim, para reduzir a influência desses parâmetros na construção dos modelos neurais, o filtro *Savitzky-Golay* de ordem 3 e tamanho de janela 101 foi aplicado aos sinais.

Tabela 7.1 – Configurações experimentais adotadas para a obtenção das assinaturas de impedância do rotor.

Condição Estrutural	Velocidade de Operação (rpm)	Classe de Condição Estrutural Avaliada no Modelo CNN
Baseline	600	0
Baseline	900	0
Baseline	1200	0
D#1	600	1
D#1	900	1
D#1	1200	1
Db#1	600	2
Db#1	900	2
Db#1	1200	2
Db#2	600	2
Db#2	900	2
Db#2	1200	2


Fonte: O autor (2021).

Ademais, em concordância com a Seção 6.2 e no intuito de reduzir o custo computacional dispendido na elaboração (treinamento e validação) dos modelos neurais convolucionais, o método de otimização por busca aleatória também foi aplicado às assinaturas de impedância desta seção, a fim de se selecionar a melhor banda de frequência para monitorar a integridade estrutural.

O procedimento de otimização da faixa de frequência aplicado às assinaturas de impedância nesta seção também foi baseado na formulação de Bento *et al.* (2017), em que a métrica de dano *RMSD* é usada como uma função objetivo, selecionando a faixa de frequência que melhor expõe a separabilidade entre os grupos danificados e a assinatura de referência do sistema. Assim, com a aplicação do método de otimização por busca aleatória, a faixa de frequência escolhida passou a ser de  $232.01\text{kHz}$  à  $250.71\text{kHz}$ , com um total de 1100 pontos amostrais.

Ressalta-se que a assinatura de referência usada no processo de otimização foi baseada na média de todas as assinaturas de impedância para a condição de baseline, independentemente da velocidade de operação do rotor. A Figura 7.5 mostra as médias das assinaturas de impedância coletadas para cada um dos estados de integridade, em relação ao PZT #1. Como as características qualitativas para o PZT #1 são semelhantes, em termos de avaliação, para o PZT #2 e PZT #3. Assim, por uma questão de brevidade, apenas as assinaturas de impedância deste transdutor são apresentadas no trabalho.

Figura 7.5 – Médias das assinaturas de impedância coletadas para o PZT #1.



Fonte: O autor (2021).

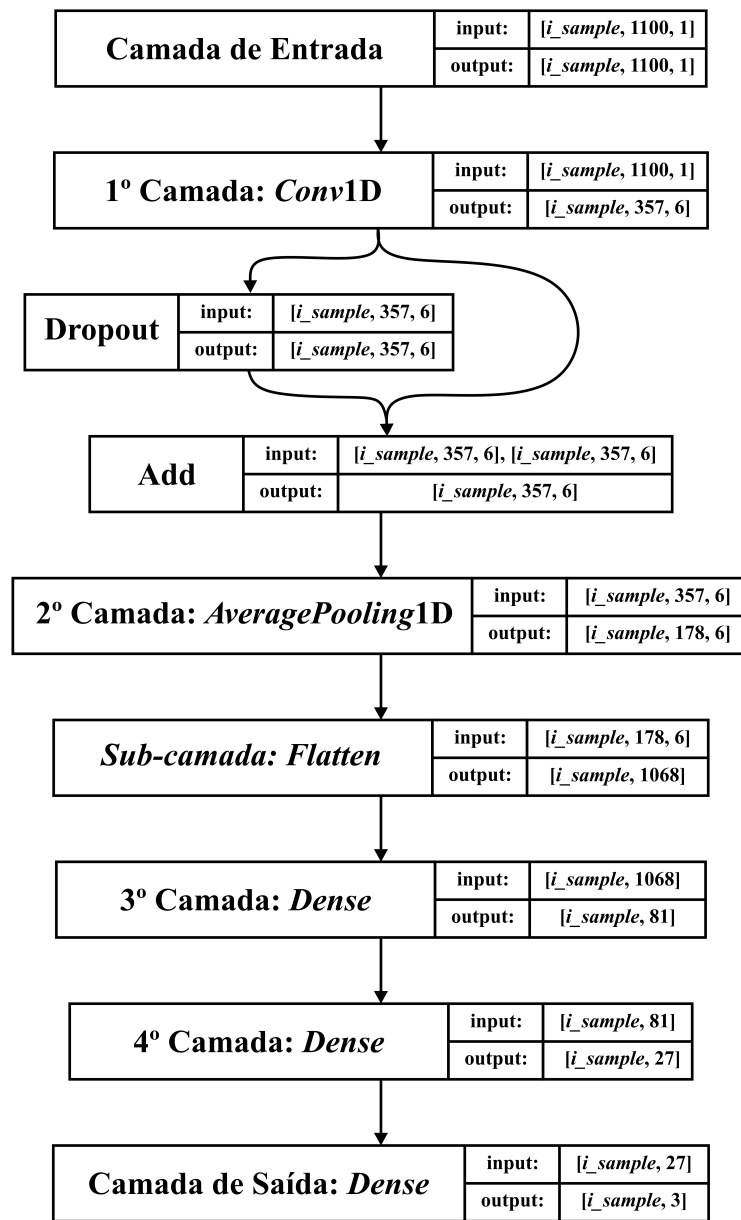
Deve-se observar que as médias dos sinais observados na Figura 7.5 para os demais estados, foram igualmente calculadas independentemente da velocidade de operação do rotor. Ainda, nota-se a existência visual de variações de magnitude e frequência nos sinais monitorados. Tais variações podem ser decorrentes de mudanças estruturais, como a presença de danos, ou das condições operacionais da estrutura hospedeira, como variação de temperatura e velocidade de rotação do rotor. Assim, métodos computacionais de abstração de padrões são necessários para se verificar corretamente a presença de falhas nesse tipo de sistema.

### 7.1.2 Construção dos Modelos CNNs

Tendo em vista que, como na Seção 6.2, as assinaturas de impedância deste estudo de caso também foram monitoradas em uma mesma faixa de frequência, que é de  $232.01\text{ kHz}$  até  $250.71\text{ kHz}$ ; portanto, será efetuada apenas uma avaliação unidimensional de todo conjunto de dados.

Para isso, uma topologia 1D CNN de 6 camadas foi desenvolvida e implementada separadamente para cada PZT mensurado. Essa topologia foi baseada na composição de uma rede neural profunda, a qual possui como componentes: uma camada de entrada, uma camada convolucional, uma camada *pooling* (do tipo *Average Pooling*) e três outras camadas totalmente conectadas, conforme mostrado na Figura 7.6.

Figura 7.6 – Arquitetura neural convolucional usada no estudo de caso desta seção.



Fonte: O autor (2021).

Ressalta-se que, assim como no problema anterior, as etapas *Dropout*, *Flatten* e *Add* não foram também consideradas na contagem destas camadas neurais, uma vez que estas servem apenas como funções de manipulação e tratamento de dados durante a fase de treinamento.

Além disso, através da Figura 7.6, pode-se observar que a etapa de *Dropout* foi desvinculada do fluxo normal de processamento da rede. Esta situação insere uma perturbação no processamento da rede durante sua etapa de treinamento, buscando assim evitar possíveis condições de *overfitting* do modelo. Ainda, destaca-se que todos os pontos de amostragem das assinaturas de impedância são considerados como entrada da arquitetura CNN.

Tal configuração, além de introduzir mais graus de liberdade ao problema, tornando sua modelagem mais tangível em termos de monitoramento da integridade estrutural, evita a necessidade de definir antecipadamente características unívocas do estado de integridade, como o uso de métricas ou etapas de pré-processamento, tornando o modelo responsável por esta finalidade.

A camada de entrada do modelo CNN, nesse sentido, foi formulada com 1100 neurônios sinápticos, cada um dos quais representava um ponto de frequência específico da assinatura de impedância. Em seguida, uma camada *Conv1D* foi formulada com 6 filtros de abstração (*kernels*) e posteriormente acoplada ao modelo. Cada filtro de abstração nesta última camada era composto por 31 pesos sinápticos escolhidos aleatoriamente e o seu processo de construção se baseou nos princípios da Seção 6.2.2.

Para o processo de convolução, o deslocamento entre os *kernels* de abstração e os dados de entrada foi atribuído como passo 3 (ou seja, *stride* = 3), a fim de se abstrair separadamente as principais partes do sinal de impedância. Essa abstração atingiu uma redução de 67.54% dos dados de entrada, convertendo-os em um vetor representativo de 357 pontos amostrais para cada filtro de abstração.

Conforme mencionado, a saída da camada convolucional foi então acoplada a um subprocesso *Dropout*, a fim de se introduzir uma perturbação nos dados de entrada durante o treinamento do modelo. Já na camada *pooling* desta seção, também foram utilizados *kernels* de tamanho dois, mantendo assim a média dos dados observados em cada *feature map*. Logo, apenas 50% dos dados de entrada são propagados para as camadas consecutivas, introduzindo uma segunda redução da dimensionalidade observada.

Após a camada *pooling*, três outras camadas totalmente conectadas foram inseridas no modelo neural, uma vez que a dimensionalidade dos dados de entrada ainda era relativamente considerável (1068) para cada amostra de impedância eletromecânica. A primeira camada densa era composta por 81 neurônios artificiais, enquanto que a segunda camada representava apenas um terço desses neurônios, ou seja, tal camada era composta por apenas 27 neurônios.

Visto que o presente estudo de caso objetiva identificar a presença de danos estruturais em um sistema de rotor, independentemente das condições ambientais de trabalho e de sua velocidade operacional. Dessa forma, a saída do modelo foi designada por meio de uma camada totalmente conectada de 3 neurônios, em que cada neurônio representava a probabilidade de a amostra em questão pertencer a uma determinada classe de saída. Tais classes, foram designadas de acordo com a coluna “Classe de Condição Estrutural Avaliada no Modelo CNN” da Tabela 7.1.

Portanto, para garantir que a camada de saída responda à probabilidade de cada assinatura de impedância pertencer a um grupo, a função de ativação logística *softmax* tam-

bém foi usada nesta seção. Conforme mencionado, esta função classifica a distribuição de entrada de dados de acordo com sua semelhança com cada classe-alvo pré-estabelecida, permitindo assim que os modelos desenvolvidos identifiquem a presença de certos tipos de anomalia (falha e desbalanceamento) no funcionamento do rotor.

### 7.1.3 Resultados e Análise do Estudo de Caso

A fim de verificar a capacidade de generalização dos modelos neurais desenvolvidos em relação à avaliação e a predição para novos dados de impedância, o conjunto de sinais monitorado durante a fase de instrumentação (Seção 7.1.1) foi separado em dois subconjuntos para cada PZT, sendo um para o treinamento da rede (contendo 270 assinaturas escolhidas aleatoriamente) e o outro (contendo as 90 assinaturas remanescentes) para fins de teste e validação desta.

Portanto, considerando que a escolha de cada assinatura pertencente a cada conjunto foi feita de forma aleatória, a formulação desses conjuntos caracterizou-se por ser desequilibrada em relação às classes avaliadas, ou seja, o número de amostras consideradas em cada classe não é proporcional. Assim, embora a situação descrita implique em uma maior complexidade no processamento dos modelos (uma vez que os torna mais sensíveis a certas características das assinaturas de impedância), a mesma faz com que esses se aproximem das condições reais de seu funcionamento, visto que em situações concretas de monitoramento, a aquisição simétrica de sinais para os diferentes estados observados nem sempre é viável.

Além disso, para verificar a repetibilidade e o desempenho das redes neurais convolucionais desenvolvidas na Seção 7.1.2, quanto à aleatoriedade introduzida na formulação de seus pesos sinápticos, um total de 20 repetições das etapas de construção, treinamento e validação de cada modelo foi executado para cada PZT avaliado. Isso ajuda a identificar a sensibilidade da metodologia imposta quanto à inicialização dos hiperparâmetros da rede neural, subsidiando assim uma posterior tomada de decisão referente à eficácia desses modelos e garantindo a visualização de possíveis casos de *underfitting*.

Os resultados das principais métricas de avaliação de um modelo neural (Seção 3.3.5) para as 20 repetições formuladas nessa seção podem ser visualizados na Tabela 7.2, na qual se encontram os valores para cada um dos PZTs avaliados.

Da Tabela 7.2, pode-se verificar que a rede neural convolucional desenvolvida para cada pastilha PZT obteve bons resultados métricos quanto à predição dos dados de teste, alcançando 0.89 (métrica  $F_1$  da 13ª execução do PZT #3) como valor mínimo de tais indicadores.

Tabela 7.2 – Métricas alcançadas para as 20 repetições dos modelos 1DCNN para todos os PZTs avaliados.

Execução	PZT #1				PZT #2				PZT #3			
	Acurácia	Precisão	Recall	F1	Acurácia	Precisão	Recall	F1	Acurácia	Precisão	Recall	F1
#1	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#2	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#3	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#4	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#5	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#6	0.933333	0.933333	0.91304	0.91296	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#7	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#8	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#9	0.97778	0.973333	0.97222	0.97162	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#10	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#11	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#12	0.96667	0.96154	0.95833	0.95737	1.00000	1.00000	1.00000	1.00000	0.933333	0.93103	0.91667	0.91392
#13	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	0.92222	0.92222	0.90278	0.89906
#14	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#15	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	0.95556	0.95062	0.94444	0.94303
#16	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#17	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#18	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#19	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
#20	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
<b>Média</b>	0.99389	0.99341	0.99218	0.99210	1.00000	1.00000	1.00000	1.00000	0.99056	0.99019	0.98819	0.98780
<b>Mediana</b>	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000	1.00000
<b>Desvio P.</b>	0.01628	0.01698	0.02103	0.02115	0.00000	0.00000	0.00000	0.00000	0.02311	0.02379	0.02889	0.02989

Fonte: O autor (2021).


Ainda, constata-se que tais modelos obtiveram como média das 20 repetições um valor de precisão de 99.34% na classificação das assinaturas coletadas pelo PZT #1, 100% para as assinaturas coletadas pelo PZT #2 e 99.02% para as assinaturas coletadas pelo PZT #3, obtendo 0.01628, 0.0000 e 0.02379 como desvio das precisões alcançadas nessas 20 repetições dos três modelos, respectivamente. Assim, tais valores mostram a eficiência da arquitetura CNN no que diz respeito à classificação dos sinais de impedância, nos parâmetros especificados nesta contribuição.

Além disso, assim como na Seção 6.2, durante cada fase do treinamento, uma função de perda de entropia cruzada foi aplicada às respostas da rede para verificar sua acurácia em relação aos valores alvo e o algoritmo RMSprop (*Root Mean Square Propagation*) foi utilizado

para ajustar, posteriormente, os pesos sinápticos.

A curva característica dos valores da função perda obtida no pior condicionamento da Tabela 7.2, ou seja, na 13<sup>o</sup> execução do modelo referente ao PZT #3, pode ser visualizada na Figura 7.7, sendo também possível notar uma redução considerável no erro observado, onde o valor final alcançado foi de 0.07567. Por uma questão de brevidade, apenas a curva da função de perda desse condicionamento é apresentada nesta contribuição, embora para outras execuções, estados semelhantes dessa curva possam ser exibidos.

Figura 7.7 – Função de perda alcançada para o 13<sup>o</sup> modelo CNN do PZT #3 durante a sua etapa de treinamento.



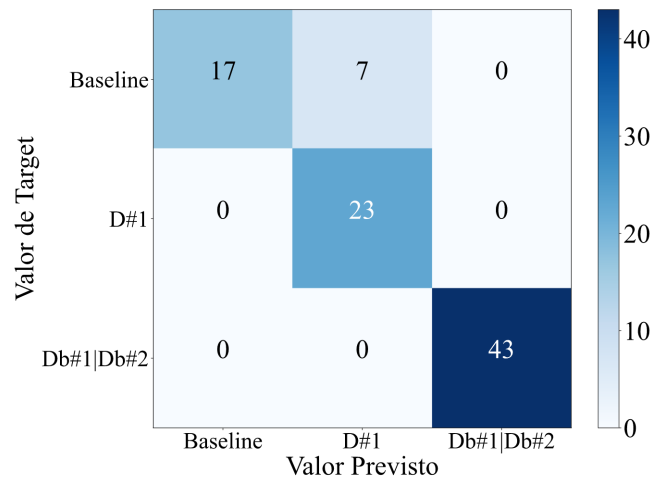
Fonte: O autor (2021).

Na Figura 7.7, pode-se observar que quando o modelo atinge a 20<sup>o</sup> época, o ajuste dos parâmetros sinápticos da rede é quase desprezível, pois a magnitude do erro observado é significativamente pequena. Assim, mesmo que nas configurações de cada rede neural convolucional utilizada, o número de épocas predefinidas fosse 100, o procedimento de *EarlyStopping* (Seção 3.3.4) foi aplicado a fim de se interromper o processo de treinamento, bem como evitar uma possível condição de *overfitting* do modelo.

Como última tratativa e a fim de demonstrar graficamente a eficácia dos modelos neurais implementados nesta contribuição, os mesmos foram validados usando tanto a matriz de confusão sobre os dados previstos por cada modelo quanto produzindo a curva ROC dessas previsões, comparando-as com os valores alvos (*targets*) pré-estabelecidos.

Assim, também por questões de brevidade e considerando a pior condição de precisão alcançada na Tabela 7.2, ou seja, a 13<sup>o</sup> execução do modelo 1DCNN do PZT #3 (cuja precisão avaliada é de 92%), a matriz de confusão adquirida na classificação das assinaturas de teste deste experimento é dada conforme a Figura 7.8.

Figura 7.8 – Matriz de Confusão dos valores previstos pela 13ª execução modelo 1DCNN do PZT #3.




Fonte: O autor (2021).

Em uma análise global verificada pela Figura 7.8, nota-se que o modelo desenvolvido é totalmente sensível às classes de dano e desbalanceamento, atingindo 100% de acerto para essas classes quando avaliadas no modelo. No entanto, para a classe de *baseline*, uma parte das assinaturas de impedância foi classificada erroneamente como condição de dano (falso negativo). Esta situação pode ser decorrente tanto da variabilidade inerente ao próprio conjunto de amostras selecionadas do grupo de assinaturas de *baseline*, ocasionando erros de análise desta classe pelo modelo, quanto pela baixa quantidade de amostras avaliadas no treinamento (visto que a seleção destas amostras ocorreu de forma aleatória) ou pela presença de ruídos ainda existentes após a aplicação do filtro *Savitzky-Golay*.

A Figura 7.9, por outro lado, mostra a curva ROC obtida a partir da comparação entre as classes previstas e os valores alvo predefinidos.

Figura 7.9 – Curva ROC dos valores previstos pela 13ª execução modelo 1DCNN do PZT #3.



Fonte: O autor (2021).

Observa-se na Figura 7.9 que as inclinações de ambas as três curvas ROC se aproximam do estado ótimo desta métrica (que é a posição (0, 1) do eixo cartesiano), sendo que a relação entre os valores de  $\nu_p$  e  $f_p$  previstos alcançaram um magnitude mínima de área sob a curva de 0.85, isto é,  $\min(AUC) = 0.85$ .

Assim, com base no que foi exposto nesta seção, pode-se verificar a eficiência e a sensibilidade dos modelos neurais convolucionais em termos de monitoramento da integridade estrutural em um rotor sob diferentes condições de operação.

Nesse sentido, e avaliando-se conjuntamente os resultados da Seção 6.2, entende-se que o uso da arquitetura 1DCNN em apoio ao método de SHM baseado em impedância eletromecânica torna-se de grande aplicabilidade, possibilitando com um certo nível de precisão a delimitação dos estados de integridade estrutural dos sistemas avaliados, independentemente das condições ambientais e operacionais aplicadas ao experimento durante a etapa de aquisição dos sinais de monitoramento.

Concluindo, através da metodologia proposta pode-se reproduzir um modelo de inferência de falhas estruturais nas condições aqui apresentadas, cuja principal característica é o aproveitamento de mais informações sobre a estrutura hospedeira, levando em consideração todos os pontos da assinatura da impedância ao invés do seu cálculo da métrica de dano, que é adotada por outras metodologias encontradas na literatura, permitindo assim uma maior veracidade para o diagnóstico estrutural.

## 7.2 Predição da Condição de Integridade de Sistemas Rotativos usando a arquitetura LSTM

### 7.2.1 Procedimento Experimental

O monitoramento periódico dos sistemas rotativos é vital na área de engenharia, devido a questões financeiras e de segurança associadas à sua quebra abrupta e a paralisação da produção (SANT'ANNA, 2007). Desta forma, o desenvolvimento de técnicas e modelos capazes de prever o momento exato em que os componentes deste tipo de sistema devem ser reparados é especialmente interessante; pois permite uma abordagem de manutenção preditiva em detrimento à corretiva, uma vez que essa é, geralmente, menos onerosa e ágil.

Ainda, outro fator igualmente relevante nesse contexto é a capacidade assistencial que tais técnicas e modelos proporcionam ao controle de produção, permitindo sua programação e planejamento mesmo quando as estruturas monitoradas se encontram em condições não ideais. Um exemplo desse cenário é a redução no desempenho de máquinas rotativas quando expostas a situações de desequilíbrio, causando perda de qualidade dos produtos a serem produzidos ou limitando-os em sua quantidade.

Assim, para simular um condicionamento no qual etapas de manutenção são aplicadas ao fluxo de processamento da estrutura de rotor (avaliada na Seção 7.1.1), foi delimitada uma configuração virtual dos sinais de impedância para descrever uma situação real de operação do sistema. Tal situação incluiu não só algumas mudanças na velocidade do rotor, para a execução de diferentes tarefas sob diferentes durezas de matéria-prima, mas também o desbalanceamento e danos inerentes à execução dessas tarefas.

Nesse sentido, a elaboração experimental adotada nesta contribuição visa verificar a capacidade de predição da magnitude das falhas estruturais em máquinas rotativas por meio da arquitetura LSTM. Isto viabiliza a tomada de decisão, quando da identificação de falhas estruturais, além de permitir a percepção de momentos críticos durante o funcionamento do rotor, nos quais os danos são intensificados e a produção vigente é reduzida.

O sequenciamento virtual das condições de integridade avaliadas nesta seção, em relação aos sinais de impedância monitorados previamente da estrutura de rotor da Seção 7.1.1, podem ser visualizados no Quadro 7.1, em que uma série de 22 estados de integridade do sistema hospedeiro foi formulada.

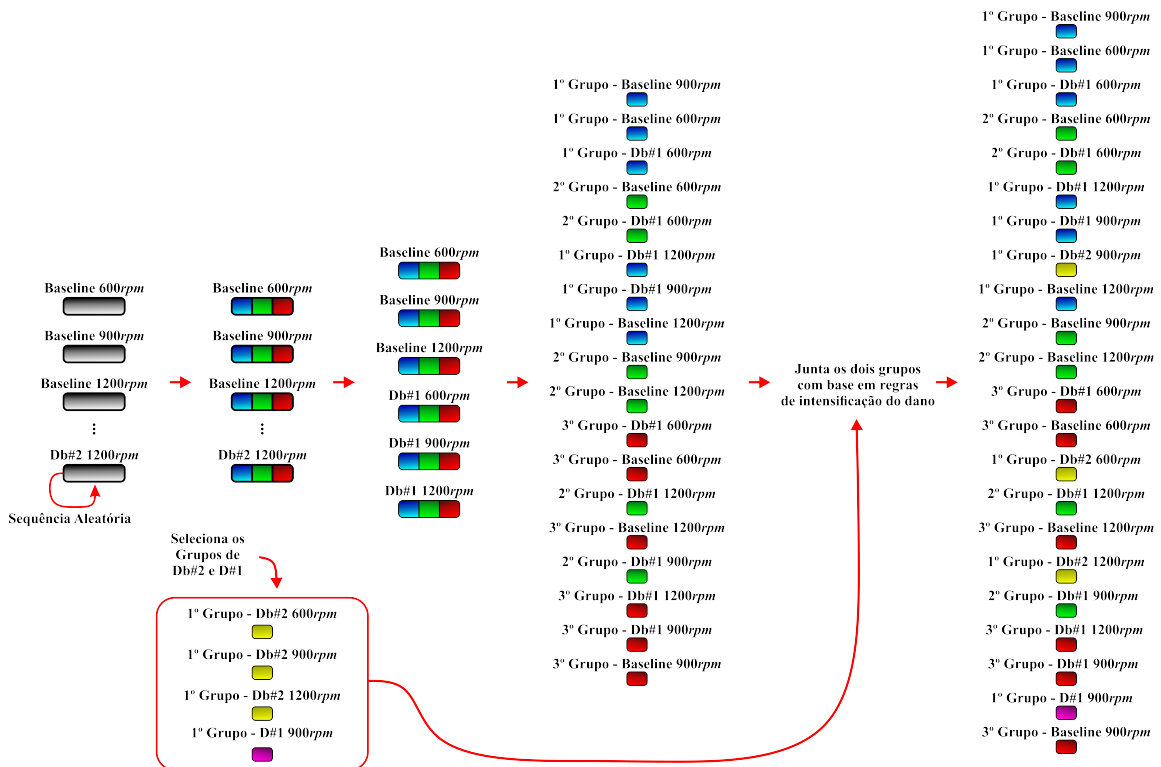
Estado	Velocidade	Condição Avaliada em Relação ao Estado Anterior
Baseline	900	Condição Inicial
Baseline	600	Alteração da Velocidade
Db#1	600	Identificação de Desbalanceamento
Baseline	600	Manutenção
Db#1	600	Identificação de Desbalanceamento
Db#1	1200	Alteração da Velocidade
Db#1	900	Alteração da Velocidade
Db#2	900	Intensificação do Desbalanceamento
Baseline	1200	Manutenção + Alteração de Velocidade
Baseline	900	Alteração da Velocidade
Baseline	1200	Alteração da Velocidade
Db#1	600	Identificação de Desbalanceamento + Alteração de Velocidade
Db#2	600	Intensificação do Desbalanceamento
Baseline	600	Manutenção
Db#1	1200	Identificação de Desbalanceamento + Alteração de Velocidade
Db#2	1200	Intensificação do Desbalanceamento
Baseline	1200	Manutenção
Db#1	900	Identificação de Desbalanceamento + Alteração de Velocidade
Db#1	1200	Alteração da Velocidade
Db#1	900	Alteração da Velocidade
D#1	900	Identificação de Dano
Baseline	900	Manutenção

Fonte: O autor (2021).

Quadro 7.1 – Sequenciamento virtual dos estados de integridade adotados para a criação dos modelos neurais LSTM.

O sequenciamento dos dados mostrado no Quadro 7.1 foi definido da seguinte forma: cada conjunto de assinaturas de impedância na Tabela 7.1 foi randomizado separadamente em seu próprio grupo e, posteriormente, dividido em 3 subgrupos de 10 amostras (ou seja, 3 subconjuntos de 10 assinaturas de impedância) para cada estado de integridade avaliado. O procedimento completo para a criação da série de dados aqui descrita pode ser visto na Figura 7.10.

Figura 7.10 – Estratégia adotada no sequenciamento dos grupos de dados para a criação da série temporal utilizada nos modelos neurais LSTM.



Fonte: O autor (2021).

Na segunda etapa, todos os subconjuntos de dados de *baseline* e *Db#1* foram reorganizados aleatoriamente para delimitar condições de integridade próximas às realidades operacionais do tipo de estrutura monitorada. Em seguida, 3 subconjuntos de desbalanceamento *Db#2* (sendo 1 de cada velocidade avaliada do rotor) e apenas um subconjunto de dano *D#1* (a 900rpm) foram inseridos de maneira aleatória imediatamente após certas posições de *Db#1*, cujas quais também foram escolhidas de forma randômica.

A conjectura adotada nesta contribuição para a inserção dos subgrupos de desbalanceamentos *Db#2* e dano *D#1* no sequenciamento dos dados utilizados, foi definida de modo a simular condições de intensificação do nível de falha monitorada, visto que, em situações naturais, a imposição de uma condição de desbalanceamento *Db#2* é usualmente dada a partir do agravamento da condição de desbalanceamento *Db#1*, fazendo-se assim jus as posições indicadas no Quadro 7.1.

Após ter sido delimitado o sequenciamento dos dados a serem utilizados no modelo

neural, esses foram devidamente filtrados empregando-se o filtro *Savitzky-Golay* com as mesmas configurações da Seção 7.1.1, de modo a reduzir as influências nocivas e inerentes ao próprio processo de coleta dos sinais de impedância.

Como passo seguinte à filtragem dos dados, estes foram então compensados e otimizados por meio da aplicação dos métodos de *Deslocamento Efetivo em Frequência por Análise de Correlação* e Método de Otimização por Busca Aleatória, respectivamente. No entanto, destaca-se que para a aplicação de tais métodos, o sinal de referência utilizado baseou-se na média das assinaturas de impedância do 1º grupo de *baseline* a 900rpm, visto que em condições reais tal grupo representaria o estado inicial do processo de monitoramento, no qual cada estado de integridade avaliado posteriormente a ele seria uma variação desse.

Todo o pré-processamento de dados aplicado a esta contribuição foi realizado de forma a maximizar o coeficiente de correlação entre os grupos de sinais avaliados, porém mantendo sentido em relação ao sequenciamento dos grupos de integridade adotados no Quadro 7.1.

Assim, como no experimento da Seção 6.3, a construção e a utilização da arquitetura LSTM empregada nesta contribuição foi baseada na avaliação de valores métricos RMSD, uma vez que estes fornecem uma melhor identificação da progressão de severidade do dano, permitindo identificar a real necessidade de aplicação dos recursos de manutenção sobre a estrutura.

Dessa forma, a equação 2.9 foi aplicada a todo o conjunto de dados da série avaliada, no entanto considerando como sinal de referência à média do 1º grupo de *baseline* a 900rpm.

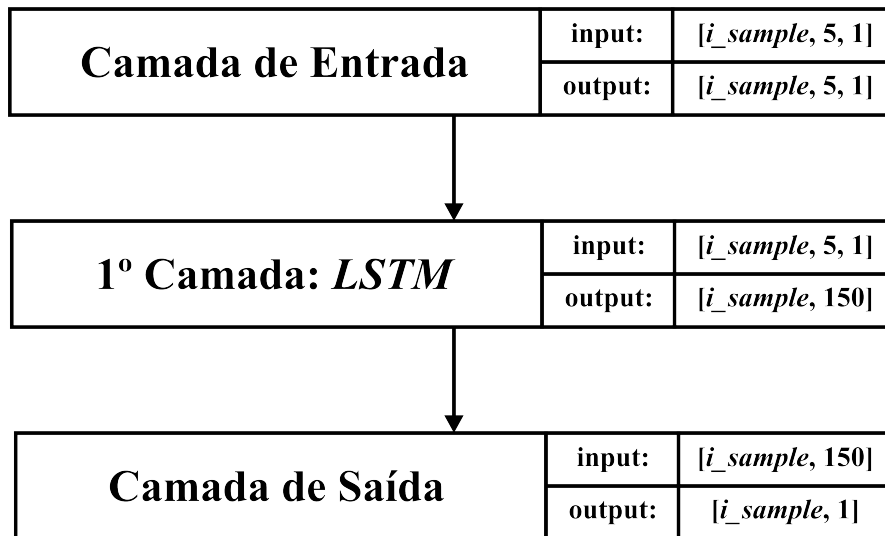
## 7.2.2 Construção do Modelo LSTM

Tendo em vista os objetivos desta dissertação no que se refere à avaliação da aplicabilidade de modelos de *deep learning* em suporte ao prognóstico de danos estruturais pelo método de SHM por impedância eletromecânica, foi aplicada neste estudo de caso a construção de uma arquitetura LSTM de 3 camadas, cuja qual é formulada de acordo com a Figura 7.11.

A partir da Figura 7.11, pode-se observar que a arquitetura neural utilizada nesta contribuição, para a predição dos valores métricos de falhas estruturais do sistema de rotor, também é composta por apenas uma única camada neural LSTM recorrente, na qual um total de 150 células de memória são empregadas para realizar a tarefa de regressão. A topologia geral da rede, no entanto, é, por sua vez, complementada por outras duas camadas neurais, sendo uma de entrada e a outra de saída.

Uma vez que, na configuração adotada, os índices métricos RSMD podem variar tanto no sentido positivo quanto negativo da condição de instante  $t$  da série temporal, a quanti-

Figura 7.11 – Arquitetura LSTM implementada no presente estudo de caso.



Fonte: O autor (2021).

dade de neurônios artificiais definidos em cada camada se faz necessária para que se possa abstrair maiores quantidades de informações do conjunto de dados. Isso permite reduzir a influência da variabilidade de cada subgrupo, bem como possibilita correlacionar os diferentes sinais de impedância utilizados na construção dos modelos neurais.

Também é importante notar que, como na Seção 6.3, a função de perda RMSE e o método de otimização conhecido como *Adam* foram aplicados na formulação dos modelos neurais LSTM desta seção, a fim de se ajustar os pesos sinápticos de cada modelo durante seus respectivos processos de treinamento.

Além disso, ressalta-se que um modelo neural LSTM foi construído e treinado separadamente para cada sensor PZT monitorado. Assim, dos 220 valores métricos de cada modelo, 88 amostras sequenciais foram removidas para teste e as 132 amostras remanescentes foram consideradas para treinar e construir o modelo neural anteriormente descrito.

Como última tratativa da construção dos modelos neurais, tanto a técnica de atraso quanto a de recorrência (fornecida pela formulação do modelo LSTM) foram aplicadas, conjuntamente, ao grupo de dados examinados. Porém, assim como no experimento da seção 6.3, para se introduzir a técnica de atraso no presente estudo de caso, foi necessário que cada ponto de previsão utilizasse suas respectivas unidades anteriores da série, o que causou também uma redução do número de pontos a serem incorporados em cada modelo.

Portanto, considerando-se o nível de atraso aplicado ( $j = 5$ ), o número de valores métricos a serem analisados na implementação das redes neurais são de 83 valores para teste e 127 amostras para treinamento da rede.

### 7.2.3 Resultados e Análise da Implementação dos Modelos Neurais LSTM

Tal como no experimento anterior, para cada transdutor PZT, um total de 20 repetições das etapas de construção, treinamento e validação foram executadas para o modelo LSTM. A aplicação desta metodologia visou verificar o desempenho e a influência dos parâmetros iniciais na rede desenvolvida. Como resultado, diferentes valores métricos foram alcançados na avaliação dados de teste, conforme pode ser visualizado na Tabela 7.3.

Tabela 7.3 – Métricas alcançadas para as 20 repetições dos modelos LSTM para todos os PZTs avaliados.

Execução	PZT #1					PZT #2					PZT #3				
	Max Error	MAE	MSE	MedAE	R <sup>2</sup>	Max Error	MAE	MSE	MedAE	R <sup>2</sup>	Max Error	MAE	MSE	MedAE	R <sup>2</sup>
#1	0.98858	0.19620	0.09150	0.12093	0.54041	2.18897	0.44454	0.43261	0.29941	0.10227	1.61316	0.26646	0.18462	0.14833	0.65626
#2	0.89203	0.26157	0.11532	0.23473	0.42074	2.24003	0.44751	0.44110	0.29817	0.08465	1.61140	0.26668	0.18474	0.13833	0.65605
#3	0.89151	0.25856	0.11358	0.23019	0.42947	2.08633	0.44447	0.42844	0.30285	0.11093	1.61303	0.26646	0.18479	0.14253	0.65596
#4	0.89456	0.26023	0.11378	0.22466	0.42847	2.25302	0.44429	0.43203	0.27556	0.10348	1.60878	0.26751	0.18493	0.13539	0.65570
#5	0.89116	0.25852	0.11345	0.22842	0.43011	2.15229	0.44392	0.42573	0.26875	0.11655	1.61641	0.26597	0.18480	0.13572	0.65594
#6	0.88967	0.25578	0.11208	0.22390	0.43704	2.05705	0.44554	0.42749	0.30419	0.11290	1.61363	0.26567	0.18402	0.14640	0.65739
#7	0.89462	0.26209	0.11431	0.22251	0.42581	2.28703	0.44490	0.43867	0.28322	0.08968	1.61256	0.26577	0.18363	0.14506	0.65811
#8	0.89190	0.26091	0.11455	0.22976	0.42461	2.27444	0.44766	0.44255	0.27325	0.08164	1.61446	0.26657	0.18555	0.13365	0.65454
#9	0.88956	0.25988	0.11478	0.23448	0.42344	2.22362	0.44719	0.43717	0.27811	0.09281	1.61396	0.26623	0.18452	0.14075	0.65646
#10	0.89035	0.25967	0.11441	0.23347	0.42532	2.16283	0.44635	0.43247	0.29224	0.10256	1.61003	0.26585	0.18396	0.14638	0.65749
#11	0.88800	0.25445	0.11233	0.22180	0.43575	2.12499	0.44538	0.43031	0.30673	0.10703	1.60827	0.26693	0.18454	0.14148	0.65643
#12	0.88909	0.26096	0.11612	0.23413	0.41670	2.27759	0.44552	0.43737	0.27255	0.09240	1.61353	0.26575	0.18371	0.14792	0.65796
#13	0.99728	0.19510	0.09219	0.12119	0.53693	2.17437	0.44611	0.43450	0.28590	0.09835	1.61458	0.26527	0.18437	0.13379	0.65674
#14	0.88934	0.25648	0.11282	0.22832	0.43332	2.23283	0.44604	0.43636	0.30133	0.09449	1.60939	0.26778	0.18511	0.13293	0.65536
#15	1.00798	0.19987	0.09366	0.11559	0.52955	2.04145	0.44551	0.42935	0.29745	0.10904	1.61127	0.26614	0.18383	0.14240	0.65775
#16	0.88682	0.25487	0.11255	0.22300	0.43467	2.28593	0.44680	0.44145	0.27259	0.08393	1.61846	0.26554	0.18453	0.14461	0.65644
#17	0.89161	0.25876	0.11372	0.22931	0.42879	2.25323	0.44645	0.44158	0.28304	0.08366	1.61077	0.26474	0.18345	0.14249	0.65844
#18	0.88451	0.25609	0.11337	0.22521	0.43056	2.07159	0.44882	0.43680	0.29601	0.09356	1.61469	0.26761	0.18567	0.13569	0.65431
#19	0.88693	0.25839	0.11441	0.23051	0.42531	2.12000	0.44487	0.42937	0.29704	0.10899	1.61246	0.26564	0.18426	0.14136	0.65693
#20	0.88772	0.25852	0.11499	0.22873	0.42237	2.17372	0.44619	0.43430	0.29805	0.09876	1.61554	0.26623	0.18472	0.13768	0.65609
Média	0.90616	0.24934	0.11070	0.21204	0.44397	2.18407	0.44590	0.43448	0.28932	0.09838	1.61282	0.26624	0.18449	0.14065	0.65652
Mediana	0.89076	0.25852	0.11365	0.22837	0.42913	2.18167	0.44579	0.43440	0.29412	0.09856	1.61310	0.26618	0.18453	0.14142	0.65643
Desvio P.	0.03876	0.02208	0.00774	0.03919	0.03886	0.07825	0.00124	0.00498	0.01211	0.01033	0.00254	0.00077	0.00058	0.00485	0.00109

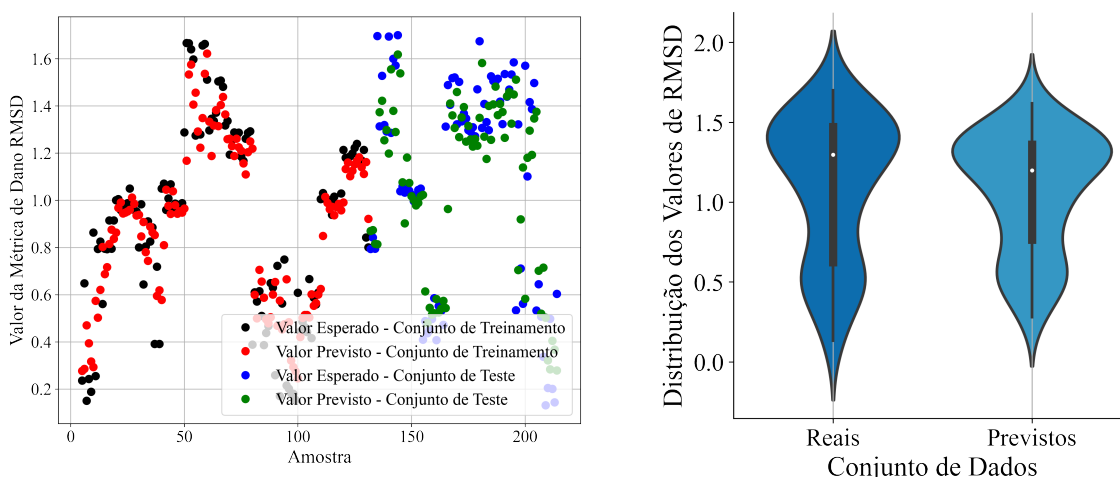
Fonte: O autor (2021).

Ressalta-se na Tabela 7.3 que embora os valores métricos tenham atingido níveis relativamente baixos devido à complexidade do problema, ainda há uma diferença de magnitude em relação aos valores previstos e reais. Esta diferença incluiu um valor médio de 0.24934 para a métrica MAE (que dentre todas é mais associada ao problema em questão) da rede LSTM do PZT #1, 0.44590 para a métrica MAE da rede LSTM do PZT #2 e 0.26624 para a métrica MAE da rede LSTM do PZT #3, com este penúltimo modelo de rede tendo os piores valores das métricas avaliadas.


No entanto, avaliando-se separadamente a melhor e a pior condição de previsão alcançada (isto é, na 1º repetição do modelo LSTM para o PZT #1 e na 18º repetição do modelo LSTM para o PZT #2, respectivamente), pode-se considerar que em ambos casos o fluxo de previsão se aproximou do ideal, atingindo distribuições semelhantes à dos valores alvo. A Figura 7.12, apresenta as relações anteriormente descritas.

Figura 7.12 – Relação entre algumas previsões dos modelos LSTM implementados nesta seção.

(a) 1º Execução do Modelo LSTM para os dados do PZT #1.



(b) 18º Execução do Modelo LSTM para os dados do PZT #2.



Fonte: O autor (2021).

Pode-se observar nas Figuras 7.12a e 7.12b que embora os modelos LSTM tenham um certo nível de ruído na predição dos valores métricos considerados, o fluxo de valor previsto obedece, em certa medida, o mesmo que o do valor real. Essa ocorrência é ainda reforçada pela semelhança entre as distribuições dos dois grupos, em que tanto a distribuição bimodal do primeiro caso quanto a distribuição unimodal do segundo caso são proporcionais às distribuições ideais.

Portanto, pode-se perceber pelo que foi exposto nesta seção que, embora com certo grau de erro, as arquiteturas neurais LSTM desenvolvidas permitem auxiliar o prognóstico de danos estruturais de sistemas rotativos, permitindo assim uma tomada de decisão quanto à manutenção das máquinas avaliadas. Isso possibilita a redução de custos desnecessários com reposição de material e paradas de produção, que têm particular interesse em processos industriais.

## Capítulo 8

---

# Considerações Finais

---

Neste capítulo, são apresentadas as considerações finais do trabalho, bem como as perspectivas de sua continuidade, incluindo descrições de possíveis melhorias e contribuições futuras. No entanto, como a presente pesquisa envolveu o desenvolvimento de duas metodologias distintas, para a integração de modelos de *deep learning* em suporte ao monitoramento de integridade estrutural (cobrindo temas e ferramentas particulares), tais considerações serão apresentadas separadamente.

### 8.1 Conclusões da Pesquisa

A presente contribuição expôs um estudo da aplicabilidade das arquiteturas CNN e LSTM em suporte ao prognóstico de vida estrutural. Para isso, tarefas de inteligência artificial (tais como a classificação e a predição de dados) foram combinadas com o método de impedância eletromecânica, visando o desenvolvimento de sistemas que auxiliem no gerenciamento da produção e no seu ciclo de manutenção.

Tendo em vista, porém, a quantidade de temas relacionados à combinação de tais ferramentas e métodos, foi realizada uma contextualização dos principais conceitos envolvidos. Desta forma, a presente pesquisa abrangeu os componentes e os princípios básicos do método de monitoramento baseado em impedância, bem como as funcionalidades e estruturas envolvidas nas arquiteturas neurais utilizadas.

Isto posto, observou-se que, embora a área de SHM tenha sido amplamente investigada nas últimas décadas, ainda faltam estudos a respeito da combinação de seus métodos com ferramentas de inteligência artificial baseadas no aprendizado profundo. Isso se torna ainda mais notável quando se trata do acoplamento das arquiteturas CNN (ou LSTM) com o método de impedância, em que apenas abordagens matriciais (imagens) ou pré-processadas foram avaliadas nas pesquisas existentes até então.

Por outro lado, quanto às abordagens experimentais adotadas nesta contribuição, fo-

ram analisados um total de quatro estudos de caso para validação das metodologias impostas, dos quais apenas dois foram aplicados em relação a cada uma das arquiteturas neurais estudadas.

No primeiro experimento referente a arquitetura CNN (Seção 6.2), um conjunto de 3 vigas de alumínio foram monitoradas em condições ambientais instáveis, a fim de se considerar um primeiro foco de aplicabilidade dessa arquitetura neural em apoio aos estudos de SHM. Assim, tal abordagem experimental foi focada especialmente em problemas em que o prognóstico de vida estrutural é influenciado por fatores externos, como a variação da temperatura e a existência de ruído na coleta de sinais de impedância.

Além disso, outro aspecto importante deste primeiro experimento em relação a esta pesquisa é que, por meio dele, foi apresentada uma modelagem introdutória do acoplamento da arquitetura CNN com o método de impedância eletromecânica, demonstrando sua eficácia através de seus resultados (obtendo uma precisão mediana de 0.97 na classificação binária de danos) e permitindo o uso desta contribuição como referência por terceiros.

Por outro lado, o segundo experimento relacionado à arquitetura CNN (Seção 7.1) teve como objetivo avaliar a eficiência das arquiteturas CNN em termos da classificação multiclasse, detectando a presença de diferentes tipos de anomalias em uma estrutura de rotor (cujo monitoramento pode ser considerado mais complexo, dadas as características inerentes ao processo de aquisição e às forças aplicadas à estrutura). Ainda, outro fator igualmente avaliado durante tal experimento foi a influência da velocidade de operação do rotor nos sinais de impedância, em que os modelos neurais desenvolvidos não deveriam ser influenciados por esse fator durante a classificação das condições de integridade da estrutura.

Ao comparar as principais métricas utilizadas em estudos de avaliação de modelos neurais, bem como a partir da análise da matriz de confusão e da curva ROC, percebeu-se que o acoplamento entre a arquitetura neural convolucional e o método da impedância permite determinar, com certo nível de precisão, a integridade do rotor. Portanto, a aplicabilidade da primeira metodologia desenvolvida nesta contribuição pode ser caracterizada sob os parâmetros aqui introduzidos.

Em relação às abordagens experimentais voltadas para a aplicação da arquitetura LSTM, no primeiro estudo de caso (Seção 6.3) duas vigas de aço foram monitoradas a fim de se possibilitar o uso do modelo neural na previsão da magnitude de falhas estruturais. Para tanto, condições progressivas de dano foram impostas nas estruturas hospedeiras através da aplicação de ácido clorídrico. Os resultados da aplicação de um modelo de *deep learning* LSTM nos valores métricos RMSD possibilitaram identificar o fluxo de evolução do dano, permitindo assim prever os estados futuros da estrutura, caso a intensidade de aplicação da falha permaneça nas mesmas condições apresentadas nesta contribuição.

No segundo estudo de caso relacionado à arquitetura LSTM (Seção 7.2), um sequenciamento virtual das condições de integridade da estrutura do rotor foi implementado para simular situações mais próximas as reais condições de operação desse tipo de sistema. Desta forma, estados de desbalanceamento e falha puderam ser monitorados a partir do agravamento ou decorrência da utilização do rotor em diferentes matérias-primas. Ainda, destaca-se que diferentes velocidades de operação do rotor foram consideradas na avaliação da sensibilidade da arquitetura LSTM.

Considerando o fluxo de previsão (Figura 7.12) e os valores métricos alcançados (Tabela 7.3) na execução das arquiteturas LSTM para os três PZTs inseridos na estrutura hospedeira (sistema de rotor), observou-se que, embora com certo grau de erro associado à metodologia, esta permite estimar as condições de funcionamento do rotor. Assim, dada a redução da produtividade devido à existência de avarias nos sistemas rotativos, os resultados possibilitam a posterior tomada de decisão quanto à manutenção de tais sistemas, bem como auxiliam o setor de planejamento na programação da produção.

Portanto, os principais pontos favoráveis deste trabalho são:

- ✓ As arquiteturas neurais profundas utilizadas (CNN e LSTM) nesta contribuição mostraram-se altamente aplicáveis no suporte ao prognóstico de dano estrutural, sob as condições aqui apresentadas. Dessa forma, tarefas de inteligência artificial tais como a classificação e a previsão dos estados de integridade estrutural de distintos sistemas mecânicos puderam ser realizadas.
- ✓ A utilização do método de SHM baseado impedância eletromecânica possibilitou identificar a presença de danos por meio da comparação dos sinais de vibração, o que é mais facilmente aplicável em estudos de sistemas reais do que a sua modelagem propriamente dita. Além disso, a utilização de sensores PZTs, bem como a aplicação de sistemas de aquisição de baixo custo proporcionam uma melhor relação custo-benefício para as metodologias desenvolvidas.
- ✓ Os modelos neurais utilizados mostraram-se invariantes às influências externas do processo de monitoramento, mas com certo nível de ruído. Isso permite estimar o estado de saúde das estruturas hospedeiras, auxiliando tanto o setor produtivo quanto o setor de planejamento.
- ✓ Os componentes utilizados no desenvolvimento de cada metodologia (incluindo a implementação computacional) foram expostos de forma a simplificar sua reprodução, bem como servir de modelo para terceiros.

Por outro lado, entre os pontos desfavoráveis desta contribuição ou possíveis melhorias a serem desenvolvidas estão:

- ✓ Os modelos neurais desenvolvidos baseiam-se na utilização de dados de apenas um único PZT separadamente, portanto, é considerado um único ponto de avaliação da estrutura, o que pode afetar a real aplicação da metodologia imposta. Desta forma, estudos mais aprofundados podem ser desenvolvidos a fim de se formular modelos mais robustos, que empreguem em conjunto diferentes pontos de avaliação de uma mesma estrutura.
- ✓ As arquiteturas neurais foram avaliadas separadamente, dessa forma estudos posteriores podem averiguar a combinação de ambas as redes neurais no suporte ao monitoramento de integridade estrutural. Ainda, tais estudos podem ser aplicados juntamente a conceitos de computação em nuvem de forma a desenvolver um sistema de monitoramento em tempo real.

---

## REFERÊNCIAS

---

- ABADI, M. *et al.* Tensorflow: Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv:1603.04467*, 2016. Citado na página 72.
- ABU-MOSTAFA, Y. S.; MAGDON-ISMAIL, M.; LIN, H.-T. *Learning from data*. [S.l.]: AMLBook New York, NY, USA, 2012. v. 4. 3-22 p. Citado 2 vezes nas páginas 46 e 61.
- AFSHARI, M. *Vibration-and Impedance-based Structural Health Monitoring Applications and Thermal Effects*. Tese (Doutorado) — Virginia Tech, 2012. Citado 5 vezes nas páginas 20, 26, 27, 42 e 88.
- AGARWAL, K. *Object Detection in Refrigerators Using Tensorflow*. Tese (Doutorado), 2018. Citado na página 87.
- AGOSTINELLI, F. *et al.* Learning activation functions to improve deep neural networks. *arXiv preprint arXiv:1412.6830*, 2014. Citado na página 55.
- ALBOY, R. G. *Técnicas de Reconhecimento de Imagem para Incorporação em Ferramentas de Auxílio a Deficientes Visuais*. Dissertação (Dissertação de Mestrado – Ciências da Computação) — Universidade Federal de São Carlos, São Carlos – SP, 2019. Citado na página 87.
- ALLEN, D. W.; PEAIRS, D. M.; INMAN, D. J. Damage detection by applying statistical methods to pzt impedance measurements. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Smart Structures and Materials 2004: Smart Structures and Integrated Systems*. [S.l.], 2004. v. 5390, p. 513–520. Citado 3 vezes nas páginas 28, 30 e 35.
- AVCI, O. *et al.* A review of vibration-based damage detection in civil structures: From traditional methods to machine learning and deep learning applications. *Mechanical Systems and Signal Processing*, Elsevier, v. 147, p. 107077, 2021. Citado 2 vezes nas páginas 20 e 21.
- BAKHARY, N.; HAO, H.; DEEKS, A. J. Damage detection using artificial neural network with consideration of uncertainties. *Engineering Structures*, Elsevier, v. 29, n. 11, p. 2806–2815, 2007. Citado na página 38.
- BAKHARY, N. *et al.* Neural network based damage detection using a substructure technique. In: ENGINEERS AUSTRALIA. *Proceedings of the 5th Australasian congress on applied mechanics*. [S.l.], 2007. p. 204. Citado na página 38.
- BALDI, P. *et al.* Bidirectional dynamics for protein secondary structure prediction. In: *Sequence Learning*. [S.l.]: Springer, 2000. p. 80–104. Citado 2 vezes nas páginas 80 e 85.

- BALDI, P.; SADOWSKI, P. The dropout learning algorithm. *Artificial intelligence*, Elsevier, v. 210, p. 78–122, 2014. Citado 3 vezes nas páginas [61](#), [62](#) e [63](#).
- BANKS, H. T.; SMITH, R. C.; WANG, Y. Smart material structures - modeling, estimation and control. *Chichester, United Kingdom, New York and Paris: John Wiley & Sons, 1996.*, 1996. Citado na página [27](#).
- BAPTISTA, F. G. *et al.* An experimental study on the effect of temperature on piezoelectric sensors for impedance-based structural health monitoring. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 14, n. 1, p. 1208–1227, 2014. Citado 2 vezes nas páginas [20](#) e [27](#).
- BAPTISTA, F. G.; FILHO, J. V. Optimal frequency range selection for pzt transducers in impedance-based shm systems. *IEEE Sensors Journal*, IEEE, v. 10, n. 8, p. 1297–1303, 2010. Citado na página [37](#).
- BAPTISTA, F. G.; FILHO, J. V.; INMAN, D. J. Real-time multi-sensors measurement system with temperature effects compensation for impedance-based structural health monitoring. *Structural Health Monitoring*, Sage Publications Sage UK: London, England, v. 11, n. 2, p. 173–186, 2012. Citado na página [20](#).
- BARELLA, B. P. *et al.* Outlier identification in impedance-based shm. In: *24th ABCM International Congress of Mechanical Engineering*. 10.26678/ABCM.COBEM2017.COB17-1487: COBEM, 2017. Citado 4 vezes nas páginas [36](#), [39](#), [41](#) e [43](#).
- BARRETT, D. G.; MORCOS, A. S.; MACKE, J. H. Analyzing biological and artificial neural networks: challenges with opportunities for synergy? *Current Opinion in Neurobiology*, Elsevier, v. 55, p. 55–64, 2019. Citado na página [49](#).
- BARROS, W. K. P.; MORAIS, D. S.; FERNANDES, M. A. C. Detecção de câncer de pele com redes neurais artificiais. In: *XIII Congresso Brasileiro de Ciências da Computação*. [S.l.: s.n.], 2017. Citado na página [46](#).
- BENGIO, Y.; LECUN, Y. *et al.* Scaling learning algorithms towards ai. *Large-Scale Kernel Machines*, v. 34, n. 5, p. 1–41, 2007. Citado na página [53](#).
- BENGIO, Y.; SIMARD, P.; FRASCONI, P. Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, IEEE, v. 5, n. 2, p. 157–166, 1994. Citado na página [81](#).
- BENTO, J. P. M. *Uso das Cadeias de Markov Associado ao Monitoramento da Integridade Estrutural Baseado em Impedância Eletromecânica*. Dissertação (Mestrado) — Universidade Federal de Goiás - Regional Catalão, 2018. Citado 7 vezes nas páginas [21](#), [27](#), [30](#), [35](#), [37](#), [41](#) e [43](#).
- BENTO, J. P. M. *et al.* Frequency range optimization by the use of aco and bco methods in the impedance-based shm. In: *24th ABCM International Congress of Mechanical Engineering*. 10.26678/ABCM.COBEM2017.COB17-1363: COBEM, 2017. Citado 3 vezes nas páginas [41](#), [89](#) e [107](#).
- BHARTI, A. K.; VERMA, N.; DEEPAK, K. V. A review on big data analytics tools in context with scalability. *International Journal of Computer Sciences and Engineering*, v. 7, n. 2, p. 273–277, 2019. Citado na página [45](#).

- BIRMAN, V. Thermal effects on measurements of dynamic processes in composite structures using piezoelectric sensors. *Smart materials and structures*, IOP Publishing, v. 5, n. 4, p. 379, 1996. Citado na página 27.
- BISHOP, C. M. *Neural Networks for Pattern Recognition*. [S.l.]: Oxford university press, 1995. Citado na página 70.
- BISPO, T. D. *Arquitetura LSTM para Classificação de Discursos de Ódio Cross-Lingual Inglês-PtBR*. Dissertação (Dissertação de Mestrado - Ciência da Computação / Computação Inteligente) — Universidade Federal de Sergipe, 2018. Citado 6 vezes nas páginas 79, 80, 82, 83, 84 e 85.
- BLANCO, A. H. *et al.* A systematic review of deep learning approaches to educational data mining. *Complexity*, Hindawi, v. 2019, 2019. Citado na página 47.
- BRAY, D. E.; MCBRIDE, D. Nondestructive testing techniques. *NASA STI/Recon Technical Report A*, v. 93, p. 17573, 1992. Citado na página 33.
- BUSCEMA, M. Back propagation neural networks. *Substance Use & Misuse*, Taylor & Francis, v. 33, n. 2, p. 233–270, 1998. Citado 2 vezes nas páginas 59 e 60.
- CAVALINI JUNIOR, A. A. *Monitoramento da Integridade Estrutural de Sistemas Mecânicos via Observador de Estado Modal*. Dissertação (Dissertação de Mestrado) — UNESP, Ilha Solteira, 2009. Citado na página 20.
- CHAUDHRY, Z. A. *et al.* Local-area health monitoring of aircraft via piezoelectric actuator/sensor patches. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Smart Structures and Materials 1995: Smart Structures and Integrated Systems*. [S.l.], 1995. v. 2443, p. 268–276. Citado na página 20.
- CHOLLET, F. *Deep Learning with Python*. [S.l.]: New York, NY, USA: Manning Publications Co., 2017. Citado 4 vezes nas páginas 77, 91, 93 e 94.
- COFRE-MARTEL, S. *et al.* Deep convolutional neural network-based structural damage localization and quantification using transmissibility data. *Shock and Vibration*, Hindawi, v. 2019, 2019. Citado 2 vezes nas páginas 46 e 72.
- DEVICES, A. *Data Sheet - AD5933 - Technical Support Analog Devices*. 2020. Disponível em: <<http://www.mouser.com/ds/2/609/AD5933-877234.pdf>>. Citado na página 43.
- DIGILENT. *PmodIA Reference Manual: Digilent - A National Instruments Company*. 2020. Disponível em: <[https://reference.digilentinc.com/\\_media/pmod:pmod:pmodia\\_rm.pdf](https://reference.digilentinc.com/_media/pmod:pmod:pmodia_rm.pdf)>. Citado 2 vezes nas páginas 43 e 44.
- DING, B.; QIAN, H.; ZHOU, J. Activation functions and their characteristics in deep neural networks. In: IEEE. *Chinese Control and Decision Conference (CCDC)*. [S.l.], 2018. p. 1836–1841. Citado na página 55.
- DOEBLING, S. W. *et al.* A summary review of vibration-based damage identification methods. *Shock and Vibration Digest*, Citeseer, v. 30, n. 2, p. 91–105, 1998. Citado na página 32.

- DUCHI, J.; SINGER, Y. Efficient online and batch learning using forward backward splitting. *The Journal of Machine Learning Research*, JMLR. org, v. 10, p. 2899–2934, 2009. Citado na página 58.
- DUMOULIN, V.; VISIN, F. A guide to convolution arithmetic for deep learning. *arXiv preprint arXiv:1603.07285*, 2016. Citado 2 vezes nas páginas 67 e 68.
- ECK, D.; SCHMIDHUBER, J. A first look at music composition using lstm recurrent neural networks. *Istituto Dalle Molle Di Studi Sull Intelligenza Artificiale*, Google Scholar, v. 103, p. 48, 2002. Citado na página 85.
- ELSWORTH, S.; GÜTTEL, S. Time series forecasting using lstm networks: A symbolic approach. *arXiv preprint arXiv:2003.05672*, 2020. Citado na página 85.
- FARIA, E. L. *Redes Neurais Convolucionais e Máquinas de Aprendizado Extremo Aplicadas ao Mercado Financeiro Brasileiro*. Dissertação (Mestrado) — Universidade Federal do Rio de Janeiro, 2018. Citado 9 vezes nas páginas 49, 50, 51, 58, 59, 62, 70, 72 e 75.
- FARRAR, C. R.; LIEVEN, N. A. J.; BEMENT, M. T. An introduction to damage prognosis. *Damage Prognosis for Aerospace, Civil and Mechanical Systems*, Wiley Online Library, 2005. Citado na página 20.
- FARRAR, C. R.; WORDEN, K. An introduction to structural health monitoring. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, The Royal Society London, v. 365, n. 1851, p. 303–315, 2007. Citado 2 vezes nas páginas 30 e 31.
- FENG, C. *et al.* Structural damage detection using deep convolutional neural network and transfer learning. *KSCE Journal of Civil Engineering*, Springer, v. 23, n. 10, p. 4493–4502, 2019. Citado 6 vezes nas páginas 38, 53, 55, 56, 71 e 75.
- FERRI, A. *Object Tracking in Video with TensorFlow*. Dissertação (Mestrado) — Universitat Politècnica de Catalunya, 2016. Citado na página 87.
- FRANCO, V. R. Monitoramento da integridade em estruturas aeronáuticas. 2009. Citado 5 vezes nas páginas 20, 28, 29, 30 e 35.
- FU, H.; COHEN, R. E. Polarization rotation mechanism for ultrahigh electromechanical response in single-crystal piezoelectrics. *Nature*, Nature Publishing Group, v. 403, n. 6767, p. 281–283, 2000. Citado na página 28.
- FUKUSHIMA, K. Cognitron: A self-organizing multilayered neural network. *Biological Cybernetics*, Springer, v. 20, n. 3-4, p. 121–136, 1975. Citado 2 vezes nas páginas 52 e 72.
- GERS, F. A.; ECK, D.; SCHMIDHUBER, J. Applying lstm to time series predictable through time-window approaches. In: *Neural Nets WIRN Vietri-01*. [S.l.]: Springer, 2002. p. 193–200. Citado na página 85.
- GIURGIUTIU, V.; KROPAS-HUGHES, C. V. Comparative study of neural network damage detection from a statistical set of electro-mechanical impedance spectra. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Smart Nondestructive Evaluation and Health Monitoring of Structural and Biological Systems II*. [S.l.], 2003. v. 5047, p. 108–119. Citado na página 21.

GIURGIUTIU, V.; ZAGRAI, A. N. Characterization of piezoelectric wafer active sensors. *Journal of Intelligent Material Systems and Structures*, Sage Publications Sage UK: London, England, v. 11, n. 12, p. 959–976, 2000. Citado na página 35.

\_\_\_\_\_. Damage detection in thin plates and aerospace structures with the electro-mechanical impedance method. *Structural Health Monitoring*, Sage Publications Sage CA: Thousand Oaks, CA, v. 4, n. 2, p. 99–118, 2005. Citado na página 40.

GIURGIUTIU, V.; ZAGRAI, A. N.; BAO, J. J. Piezoelectric wafer embedded active sensors for aging aircraft structural health monitoring. *Structural Health Monitoring*, Sage Publications Sage CA: Thousand Oaks, CA, v. 1, n. 1, p. 41–61, 2002. Citado na página 35.

GLOROT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. In: *Proceedings of the thirteenth international conference on artificial intelligence and statistics*. [S.l.: s.n.], 2010. p. 249–256. Citado 2 vezes nas páginas 54 e 55.

GOLDSBOROUGH, P. A tour of tensorflow. *arXiv preprint arXiv:1610.01178*, 2016. Citado na página 87.

GONSALEZ, C. G. *Metodologias para reconhecimento de padrões em sistemas de SHM utilizando a técnica da Impedância Eletromecânica*. Dissertação (Mestrado) — Faculdade de Engenharia de Ilha Solteira da Universidade Estadual Paulista, Ilha Solteira, 2012. Citado na página 32.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*, MIT press. 2016. Disponível em: <<https://www.deeplearningbook.org/contents/ml.html>>. Citado 12 vezes nas páginas 46, 48, 49, 53, 54, 56, 57, 64, 66, 70, 72 e 73.

GRAVES, A. *et al.* Unconstrained on-line handwriting recognition with recurrent neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2008. p. 577–584. Citado na página 85.

GRUPPIONI, H. C. P.; Moura Jr, J. R. V.; RADE, R. S. L. Avaliação do método da impedância para detecção de falhas em uma viga de alumínio-cobre. In: *FEMEC. 16º Simpósio de Pós-Graduação em Engenharia Mecânica*. [S.l.]: Universidade Federal de Uberlândia, 2006. Citado na página 42.

GULGEC, N. S.; TAKÁČ, M.; PAKZAD, S. N. Structural damage detection using convolutional neural networks. In: *Model validation and uncertainty quantification, Volume 3*. [S.l.]: Springer, 2017. p. 331–337. Citado 4 vezes nas páginas 21, 46, 47 e 91.

\_\_\_\_\_. Convolutional neural network approach for robust structural damage detection and localization. *Journal of Computing in Civil Engineering*, American Society of Civil Engineers, v. 33, n. 3, p. 04019005, 2019. Citado 2 vezes nas páginas 47 e 94.

GULLI, A.; PAL, S. *Deep learning with Keras*. [S.l.]: Packt Publishing Ltda, 2017. Citado na página 100.

HAFEMANN, L. G. *An Analysis of Deep Neural Networks for Texture Classification*. Dissertação (Mestrado) — Program in Informatics, Universidade Federal do Paraná, 2014. Citado na página 58.

HARRISON, M. *Machine Learning - Guia de Referência Rápida*. first. Rua Luís Antônio dos Santos 110: Novatec Editora Ltda, 2020. Trabalhando com dados estruturados em Python. Citado na página 65.

HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2007. Citado 9 vezes nas páginas 48, 49, 50, 51, 53, 54, 55, 57 e 58.

HAYT JR, W. H.; KEMMERLY, J. E.; DURBIN, S. M. *Análise de Circuitos em Engenharia*. São Paulo: AMGH Editora, 2014. v. 8. Citado na página 34.

HE, K. *et al.* Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778. Citado na página 71.

HIJAZI, S.; KUMAR, R.; ROWEN, C. Using convolutional neural networks for image recognition. *Cadence Design Systems Inc.: San Jose, CA, USA*, p. 1–12, 2015. Citado na página 75.

HINTON, G. E. *et al.* Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*, 2012. Citado 2 vezes nas páginas 61 e 62.

HOCHREITER, S. The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, World Scientific, v. 6, n. 02, p. 107–116, 1998. Citado na página 83.

HOCHREITER, S. *et al.* *Gradient Flow in Recurrent Nets: The Difficulty of Learning Long-Term Dependencies*. [S.l.]: A field guide to dynamical recurrent neural networks. IEEE Press, 2001. Citado na página 82.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, MIT Press, v. 9, n. 8, p. 1735–1780, 1997. Citado 4 vezes nas páginas 52, 81, 82 e 83.

HOI, S. C. H. *et al.* Online learning: A comprehensive survey. *arXiv preprint arXiv:1802.02871*, 2018. Citado na página 57.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, National Acad Sciences, v. 79, n. 8, p. 2554–2558, 1982. Citado na página 51.

\_\_\_\_\_. Neurons with graded response have collective computational properties like those of two-state neurons. *Proceedings of the national academy of sciences*, National Acad Sciences, v. 81, n. 10, p. 3088–3092, 1984. Citado 2 vezes nas páginas 46 e 51.

HU, X.; ZHU, H.; WANG, D. A study of concrete slab damage detection based on the electro-mechanical impedance method. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 14, n. 10, p. 19897–19909, 2014. Citado 2 vezes nas páginas 30 e 35.

INDOLIA, S. *et al.* Conceptual understanding of convolutional neural network - a deep learning approach. *Procedia computer science*, Elsevier, v. 132, p. 679–688, 2018. Citado na página 76.

INMAN, D. J. Smart structures: examples and new problems. In: ABCM. *XVI Congresso Brasileiro de Engenharia Mecânica*. Uberlândia, 2001. p. 4–13. Citado na página 32.

- ISLAM, M.; HUANG, H. Effects of adhesive thickness on the lamb wave pitch-catch signal using bonded piezoelectric wafer transducers. *Smart Materials and Structures*, IOP Publishing, v. 25, n. 8, p. 085014, 2016. Citado na página 28.
- JABBAR, H.; KHAN, R. Z. Methods to avoid over-fitting and under-fitting in supervised machine learning (comparative study). *Computer Science, Communication and Instrumentation Devices*, p. 163–172, 2015. Citado 2 vezes nas páginas 60 e 61.
- JIANG, S. F.; ZHANG, C. M.; KOH, C. G. Structural damage detection by integrating data fusion and probabilistic neural network. *Advances in Structural Engineering*, SAGE Publications Sage UK: London, England, v. 9, n. 4, p. 445–458, 2006. Citado 2 vezes nas páginas 21 e 22.
- JIANG, Y. *et al.* A brief review of neural networks based learning and control and their applications for robots. *Complexity*, Hindawi, v. 2017, 2017. Citado na página 49.
- KAREVAN, Z.; SUYKENS, J. A. Transductive lstm for time-series prediction: An application to weather forecasting. *Neural Networks*, Elsevier, v. 125, p. 1–9, 2020. Citado na página 85.
- KIM, I.; RAJARAMAN, S.; ANTANI, S. Visual interpretation of convolutional neural network predictions in classifying medical image modalities. *Diagnostics*, Multidisciplinary Digital Publishing Institute, v. 9, n. 2, p. 38, 2019. Citado na página 72.
- KOBAYASHI, M. *et al.* Structural health monitoring of composites using integrated and flexible piezoelectric ultrasonic transducers. *Journal of intelligent material systems and structures*, Sage Publications Sage UK: London, England, v. 20, n. 8, p. 969–977, 2009. Citado na página 26.
- KOHONEN, T. The self-organizing map. *Proceedings of the IEEE*, IEEE, v. 78, n. 9, p. 1464–1480, 1990. Citado 4 vezes nas páginas 46, 52, 56 e 57.
- KOMAL, M. S. A review paper on big data analytics tools. *International Journal of Technical Innovation in Modern Engineering & Science (IJTIMES)*, v. 4, 2018. Citado na página 45.
- KOO, K.-Y. *et al.* Automated impedance-based structural health monitoring incorporating effective frequency shift for compensating temperature effects. *Journal of intelligent material systems and structures*, Sage Publications Sage UK: London, England, v. 20, n. 4, p. 367–377, 2009. Citado na página 40.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2012. p. 1097–1105. Citado 2 vezes nas páginas 70 e 72.
- KUDELA, P. *et al.* Structural health monitoring system based on a concept of lamb wave focusing by the piezoelectric array. *Mechanical Systems and Signal Processing*, Elsevier, v. 108, p. 21–32, 2018. Citado na página 22.
- KUO, C.-C. J. Understanding convolutional neural networks with a mathematical model. *Journal of Visual Communication and Image Representation*, Elsevier, v. 41, p. 406–413, 2016. Citado na página 75.
- LE, X.-H. *et al.* Application of long short-term memory (lstm) neural network for flood forecasting. *Water*, Multidisciplinary Digital Publishing Institute, v. 11, n. 7, p. 1387, 2019. Citado 3 vezes nas páginas 80, 83 e 84.

LECUN, Y. *et al.* Backpropagation applied to handwritten zip code recognition. *Neural computation*, MIT Press, v. 1, n. 4, p. 541–551, 1989. Citado na página 72.

\_\_\_\_\_. A theoretical framework for back-propagation. In: CMU, PITTSBURGH, PA: MORGAN KAUFMANN. *Proceedings of the 1988 connectionist models summer school*. [S.l.], 1988. v. 1, p. 21–28. Citado na página 58.

LEE, C.-Y.; GALLAGHER, P. W.; TU, Z. Generalizing pooling functions in convolutional neural networks: Mixed, gated, and tree. In: *Artificial intelligence and statistics*. [S.l.: s.n.], 2016. p. 464–472. Citado 2 vezes nas páginas 75 e 76.

LEI, J.; LIU, C.; JIANG, D. Fault diagnosis of wind turbine based on long short-term memory networks. *Renewable energy*, Elsevier, v. 133, p. 422–432, 2019. Citado na página 22.

LEI, Q. *et al.* Design and experiment of pzt network-based structural health monitoring scanning system. *Chinese Journal of Aeronautics*, Elsevier, v. 22, n. 5, p. 505–512, 2009. Citado na página 21.

LETTY, L. *et al.* Repeated pattern detection using cnn activations. In: IEEE. *Winter Conference on Applications of Computer Vision (WACV)*. [S.l.], 2017. p. 47–55. Citado na página 70.

LEUCAS, L. D. F. *Utilização das técnicas de impedância eletromecânica e ondas de Lamb para identificação de dano em estruturas com rebites*. Dissertação (Mestrado) — Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia, 2009. Citado na página 38.

LI, L. *et al.* Deep learning-based sensor fault detection using s-long short-term memory networks. *Structural Monitoring and Maintenance*, Techno-Press, v. 5, n. 1, p. 51–65, 2018. Citado 2 vezes nas páginas 84 e 85.

LIANG, C.; SUN, F. P.; ROGERS, C. A. Coupled electro-mechanical analysis of adaptive material systems-determination of the actuator power consumption and system energy transfer. *Journal of intelligent material systems and structures*, TECHNOMIC PUBLISHING CO., INC. 851 New Holland Ave., Box 3535, Lancaster, PA ... , v. 8, n. 4, p. 335–343, 1997. Citado na página 35.

\_\_\_\_\_. An impedance method for dynamic analysis of active material systems. *Journal of intelligent material systems and structures*, TECHNOMIC PUBLISHING CO., INC. 851 New Holland Ave., Box 3535, Lancaster, PA ... , v. 8, n. 4, p. 323–334, 1997. Citado na página 36.

LIANG, W.; GUIXI, L.; HONGYAN, D. Dynamic and combined gestures recognition based on multi-feature fusion in a complex environment. *The Journal of China Universities of Posts and Telecommunications*, Elsevier, v. 22, n. 2, p. 81–88, 2015. Citado na página 46.

LIMA, W. *Transdutores de deformação à base de sensores piezoelétricos*. Tese (Doutorado) — Dissertação de Mestrado, Universidade Federal Fluminense, Rio de Janeiro, 2013. Citado na página 28.

LIN, Z.; LIU, Y.; ZHOU, L. Damage detection in a benchmark structure using long short-term memory networks. In: IEEE. *2019 Chinese Automation Congress (CAC)*. [S.l.], 2019. p. 2300–2305. Citado na página 22.

- LIU, H.; LEE, B.; TARNG, Y. In-process prediction of corner wear in drilling operations. *Journal of Materials Processing Technology*, Elsevier, v. 101, n. 1-3, p. 152–158, 2000. Citado na página 52.
- LU, G. *et al.* Characterization of ultrasound energy diffusion due to small-size damage on an aluminum plate using piezoceramic transducers. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 17, n. 12, p. 2796, 2017. Citado na página 27.
- LUAN, Y.; LIN, S. Research on text classification based on cnn and lstm. In: IEEE. *2019 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA)*. [S.l.], 2019. p. 352–355. Citado na página 85.
- MAIO, C. E. B. *Técnicas para monitoramento de integridade estrutural usando sensores e atuadores piezoelétricos*. Tese (Doutorado) — Universidade de São Paulo, 2011. Citado 4 vezes nas páginas 21, 26, 30 e 32.
- MANAVAZHAHAN, M. A study of activation functions for neural networks. *Computer Science and Computer Engineering*, 2017. Citado na página 54.
- MANTOVANI, W. A. *Utilização de redes neurais recorrentes na caracterização de cargas não lineares em sistemas elétricos*. Dissertação (Mestrado) — Engenharia Elétrica, UNESP, Campus Ilha Solteira, 2011. Citado 2 vezes nas páginas 79 e 80.
- MARQUI, C. R. *Modelagem de estruturas piezoelétricas para aplicação em localização de falhas*. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), Ilha Solteira, 2007. Citado na página 33.
- MASSUCATTO, J. D. P. *Aplicação de conceitos de redes neurais convolucionais na classificação de imagens de folhas*. Dissertação (B.S. thesis) — (UTFPR) Universidade Tecnológica Federal do Paraná, Pato Branco, 2018. Citado 2 vezes nas páginas 47 e 68.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943. Citado na página 49.
- MENEZES, F. C. d. *et al.* Redes neurais artificiais aplicadas ao processo de coagulação. *Engenharia Sanitaria e Ambiental*, SciELO Brasil, v. 14, n. 4, p. 449–454, 2009. Citado na página 46.
- METROLOG, C. M. *Piezofilme Série LDT1-028K*. 2020. Disponível em: <<https://www.metrolog.net/ldt1028k.php?lang=ptbr>>. Citado na página 29.
- MHASKAR, H. N.; MICCHELLI, C. A. How to choose an activation function. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 1994. p. 319–326. Citado 2 vezes nas páginas 54 e 55.
- MHATRE, S. M. *et al.* A review paper on artificial neural network: A prediction technique. *International Journal of Scientific and Engineering Research (IJSER)*, v. 8, p. 2229–5518, 2017. Citado 4 vezes nas páginas 46, 47, 55 e 56.
- MILLSTEIN, F. *Convolutional neural networks in python: Beginner's guide to convolutional neural networks in python*. CreateSpace Independent Publishing Platform, North Charleston, SC, USA, 2018. Citado na página 100.

- MIN, J. *et al.* Impedance-based structural health monitoring incorporating neural network technique for identification of damage type and severity. *Engineering Structures*, Elsevier, v. 39, p. 210–220, 2012. Citado 2 vezes nas páginas 21 e 22.
- MINSKY, M.; PAPERT, S. A. *Perceptrons: An introduction to computational geometry*. [S.l.]: MIT press, 2017. Citado na página 51.
- MISHRA, R.; JAIN, S.; PRASAD, C. D. A review on piezoelectric material as a source of generating electricity and its possibility to fabricate devices for daily uses of army personnel. *International Journal of Systems, Control and Communications*, Inderscience Publishers (IEL), v. 6, n. 3, p. 212–221, 2015. Citado na página 26.
- MOHSEN, H. *et al.* Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, Elsevier, v. 3, n. 1, p. 68–71, 2018. Citado na página 47.
- MONTANEZ, C. “What is a Piezoelectric Ceramic?”. *Advanced Ceramic Materials*. 2019. Disponível em: <<https://www.preciseceramic.com/blog/what-is-a-piezoelectric-ceramic/>>. Citado na página 29.
- MOURA JR, J. R. V. *Uma contribuição aos sistemas de monitoramento de integridade estrutural aplicada a estruturas aeronáuticas e espaciais*. Dissertação (Tese de Doutorado) — Universidade Federal de Uberlândia, 2008. Citado 14 vezes nas páginas 20, 21, 26, 27, 28, 30, 38, 40, 46, 49, 50, 53, 54 e 55.
- MOURA JR, J. R. V.; STEFFEN JR, V. Impedance-based health monitoring: frequency band evaluation. In: *Proceedings of the 22nd International Modal Analysis Conference (IMAC XXII)*, Detroit, Michigan, USA. [S.l.: s.n.], 2004. Citado 4 vezes nas páginas 28, 30, 35 e 37.
- \_\_\_\_\_. Impedance-based health monitoring for aeronautic structures using statistical meta-modeling. *Journal of Intelligent Material Systems and Structures*, Sage Publications Sage CA: Thousand Oaks, CA, v. 17, n. 11, p. 1023–1036, 2006. Citado 3 vezes nas páginas 30, 33 e 35.
- MULLAINATHAN, S.; SPIESS, J. Machine learning: An applied econometric approach. *Journal of Economic Perspectives*, v. 31, n. 2, p. 87–106, 2017. Citado na página 45.
- MURPHY, S. D.; KAIRISS, E. W. Model of a biological neuron as a temporal neural network. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 1995. p. 85–91. Citado na página 49.
- NAGI, J. *et al.* Max-pooling convolutional neural networks for vision-based hand gesture recognition. In: IEEE. *2011 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*. [S.l.], 2011. p. 342–347. Citado na página 75.
- NAIDU, A.; SOH, C. Damage severity and propagation characterization with admittance signatures of piezo transducers. *Smart materials and structures*, IOP Publishing, v. 13, n. 2, p. 393, 2004. Citado na página 40.
- NASA. *Mechanical and Fluid Systems – Macro-Fiber Composite (MFC) Actuator*. National Aeronautics and Space Administration. 2007. Disponível em: <<https://ntts-prod.s3.amazonaws.com/t2p/prod/t2media/tops/pdf/LAR-TOPS-209.pdf>>. Citado na página 30.

\_\_\_\_\_. *Technology Transfer Program. Piezoelectric Fiber Composite Actuator Portfolio*. 2020. Disponível em: <[https://ntts-prod.s3.amazonaws.com/t2p/prod/t2media/tops/img/LAR-TOPS-17/TOP40\\_front.jpg](https://ntts-prod.s3.amazonaws.com/t2p/prod/t2media/tops/img/LAR-TOPS-17/TOP40_front.jpg)>. Citado na página 30.

NIELSEN, M. A. *Neural Networks and Deep Learning*. [S.l.]: Determination press San Francisco, CA, 2015. v. 2018. Citado 2 vezes nas páginas 60 e 61.

NOWAK, J.; TASPINAR, A.; SCHERER, R. Lstm recurrent neural networks for short text and sentiment classification. In: SPRINGER. *International Conference on Artificial Intelligence and Soft Computing*. [S.l.], 2017. p. 553–562. Citado na página 85.

NWANKPA, C. *et al.* Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*, 2018. Citado 3 vezes nas páginas 53, 54 e 55.

ODON, A. Probe with pvdF sensor for energy measurements of optical radiation. *Measurement Science Review*, v. 3, n. Section 3, p. 111–114, 2003. Citado na página 29.

OLIVEIRA, M. A.; MONTEIRO, A. V.; FILHO, J. V. A new structural health monitoring strategy based on pzt sensors and convolutional neural network. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 18, n. 9, p. 2955, 2018. Citado 2 vezes nas páginas 22 e 23.

OLIVEIRA, S. A. *Modelagem Termomecânica De Ligas Com Memória De Forma Em Um Contexto Tridimensional*. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2013. Citado na página 26.

OLIVERA, A. R. *et al.* Comparison of machine-learning algorithms to build a predictive model for detecting undiagnosed diabetes-elsa-brasil: accuracy study. *Sao Paulo Medical Journal*, SciELO Brasil, v. 135, n. 3, p. 234–246, 2017. Citado na página 63.

O'SHEA, K.; NASH, R. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*, 2015. Citado na página 75.

PALOMINO, L. V. *et al.* Análise das métricas de dano associadas à técnica da impedância eletromecânica para o monitoramento de integridade estrutural. Universidade Federal de Uberlândia, 2008. Citado 4 vezes nas páginas 28, 35, 37 e 42.

PALOMINO, L. V.; STEFFEN JR, V.; FINZI NETO, R. M. Probabilistic neural network and fuzzy cluster analysis methods applied to impedance-based shm for damage classification. *Shock and Vibration*, Hindawi, v. 2014, 2014. Citado na página 20.

PARK, G.; INMAN, D. J. Smart bolts: An example of self-healing structures. *Smart Materials Bulletin*, Elsevier, v. 2001, n. 7, p. 5–8, 2001. Citado 2 vezes nas páginas 26 e 40.

PARK, G. *et al.* Impedance-based structural health monitoring for temperature varying applications. *JSME International Journal Series A Solid Mechanics and Material Engineering*, The Japan Society of Mechanical Engineers, v. 42, n. 2, p. 249–258, 1999. Citado 3 vezes nas páginas 30, 35 e 41.

PARMEZAN, A. R. S.; SOUZA, V. M. A.; BATISTA, G. E. Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model. *Information Sciences*, Elsevier, v. 484, p. 302–337, 2019. Citado 2 vezes nas páginas 63 e 64.

- PAWADE, D. *et al.* Story scrambler-automatic text generation using word level rnn-lstm. *International Journal of Information Technology and Computer Science (IJITCS)*, v. 10, n. 6, p. 44–53, 2018. Citado na página 85.
- PHAISANGITTISAGUL, E. An analysis of the regularization between l2 and dropout in single hidden layer neural network. In: IEEE. *7th International Conference on Intelligent Systems, Modelling and Simulation (ISMS)*. [S.l.], 2016. p. 174–179. Citado na página 61.
- PICZAK, K. J. Environmental sound classification with convolutional neural networks. In: IEEE. *25th International Workshop on Machine Learning for Signal Processing (MLSP)*. [S.l.], 2015. p. 1–6. Citado na página 78.
- PROVOST, F.; KOHAVI, R. Glossary of terms. *Journal of Machine Learning*, v. 30, n. 2-3, p. 271–274, 1998. Citado 2 vezes nas páginas 45 e 46.
- RABELO, D. S. *Monitoramento de integridade estrutural baseado na técnica da impedância eletromecânica incorporando compensação do efeito da variação da temperatura*. Dissertação (Mestrado) — Faculdade de Engenharia de Mecânica, Universidade Federal de Uberlândia, Uberlândia, 2014. Citado 4 vezes nas páginas 27, 28, 29 e 34.
- RABELO, D. S. *et al.* Impedance-based structural health monitoring and statistical method for threshold-level determination applied to 2024-t3 aluminum panels under varying temperature. *Structural Health Monitoring*, SAGE Publications Sage UK: London, England, v. 16, n. 4, p. 365–381, 2017. Citado 4 vezes nas páginas 30, 40, 88 e 98.
- \_\_\_\_\_. Fault detection of a rotating shaft by using the electromechanical impedance method and a temperature compensation approach. *Journal of Nondestructive Evaluation*, Springer, v. 36, n. 2, p. 25, 2017. Citado 3 vezes nas páginas 28, 39 e 88.
- RAJU, V. *Implementing Impedance-Based Health Monitoring*. Tese (Doutorado) — Virginia Tech, 1997. Citado 3 vezes nas páginas 36, 37 e 40.
- RAMOS NETO, G. M. *Reconhecimento de Língua de Sinais Baseado em Redes Neurais Convolucionais 3D*. Dissertação (Mestrado) — UFMA, Universidade Federal do Maranhão, 2018. Citado na página 59.
- RAMPASEK, L.; GOLDENBERG, A. Tensorflow: Biology's gateway to deep learning? *Cell systems*, Elsevier, v. 2, n. 1, p. 12–14, 2016. Citado na página 87.
- RAO, A.; SPASOJEVIC, N. Actionable and political text classification using word embeddings and lstm. *arXiv preprint arXiv:1607.02501*, 2016. Citado na página 85.
- RAWAT, W.; WANG, Z. Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, MIT Press, v. 29, n. 9, p. 2352–2449, 2017. Citado na página 78.
- REICH, Y.; BARAI, S. V. Evaluating machine learning models for engineering problems. *Artificial Intelligence in Engineering*, Elsevier, v. 13, n. 3, p. 257–272, 1999. Citado na página 63.
- RHIM, J.; LEE, S. W. A neural network approach for damage detection and identification of structures. *Computational mechanics*, Springer, v. 16, n. 6, p. 437–443, 1995. Citado na página 38.

- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, American Psychological Association, v. 65, n. 6, p. 386, 1958. Citado na página 50.
- ROUHANI, S. *Reconhecimento de face e de prova de vida com Tensorflow para criação de um sistema de segurança voltado a residências e a ambientes de acesso restrito*. Tese (Doutorado) — Universidade de São Paulo, 2019. Citado na página 87.
- RUDER, S. An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*, 2016. Citado na página 59.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *nature*, Nature Publishing Group, v. 323, n. 6088, p. 533–536, 1986. Citado 4 vezes nas páginas 52, 53, 58 e 80.
- SAFAEI, M.; SODANO, H. A.; ANTON, S. R. A review of energy harvesting using piezoelectric materials: State-of-the-art a decade later (2008–2018). *Smart Materials and Structures*, IOP Publishing, v. 28, n. 11, p. 113001, 2019. Citado na página 26.
- SAINATH, T. N. *et al.* Convolutional, long short-term memory, fully connected deep neural networks. In: IEEE. *International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. [S.l.], 2015. p. 4580–4584. Citado na página 52.
- SALAKHUTDINOV, R. Learning deep generative models. *Annual Review of Statistics and Its Application*, Annual Reviews, v. 2, p. 361–385, 2015. Citado 2 vezes nas páginas 46 e 53.
- SALDARRIAGA, M. V. *et al.* Adaptive balancing of highly flexible rotors by using artificial neural networks. *Smart Structures and Systems*, Techno-Press, v. 5, n. 5, p. 507–515, 2009. Citado na página 22.
- SANTANA, L. M. Q. *et al.* Deep neural networks for acoustic modeling in the presence of noise. *Latin America Transactions, IEEE*, v. 16, n. 3, p. 918–925, 2018. Citado 2 vezes nas páginas 83 e 84.
- SANT’ANNA, R. *Análise de Acidente com Rotor*. Dissertação (Programa de Pós-graduação em Engenharia Mecânica do Departamento de Engenharia Mecânica do Centro Técnico Científico da PUC–Rio.) — Pontifca Universidade Católica do Rio de Janeiro, 2007. Citado na página 115.
- SANTHANAM, S. Context based text-generation using lstm networks. *arXiv preprint arXiv:2005.00048*, 2020. Citado na página 85.
- SARAVANAN, T. J.; GOPALAKRISHNAN, N.; RAO, N. P. Damage detection in structural element through propagating waves using radially weighted and factored rms. *Measurement*, Elsevier, v. 73, p. 520–538, 2015. Citado na página 31.
- SCIKIT-LEARN. *Receiver Operating Characteristic - ROC*. 2020. Disponível em: <[https://scikit-learn.org/stable/auto\\_examples/model\\_selection/plot\\_roc.html](https://scikit-learn.org/stable/auto_examples/model_selection/plot_roc.html)>. Citado na página 66.
- SEGATTO, E. C.; COURY, D. V. Redes neurais artificiais recorrentes aplicadas na correção de sinais distorcidos pela saturação de transformadores de corrente. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, SciELO Brasil, v. 17, n. 4, p. 424–436, 2006. Citado na página 51.

- SELEEMAH, A. A.; ABOU-RAYAN, A. M.; SAMY, M. A neural network model for damage detection of el-ferdan bridge. In: *Fourth International Conference on Structural Stability and Dynamics, ICSSD-2012, India*. [S.l.: s.n.], 2012. p. 775–783. Citado na página 38.
- SEPEHRY, N.; SHAMSHIRSAZ, M.; BASTANI, A. Experimental and theoretical analysis in impedance-based structural health monitoring with varying temperature. *Structural Health Monitoring*, Sage Publications Sage UK: London, England, v. 10, n. 6, p. 573–585, 2011. Citado na página 43.
- SHARMA, J.; GRANMO, O.-C.; GOODWIN, M. Environment sound classification using multiple feature channels and deep convolutional neural networks. *arXiv preprint arXiv:1908.11219*, 2019. Citado na página 78.
- SHARMA, N.; JAIN, V.; MISHRA, A. An analysis of convolutional neural networks for image classification. *Procedia computer science*, Elsevier, v. 132, p. 377–384, 2018. Citado na página 67.
- SHARMA, P; SINGH, A. Era of deep neural networks: A review. In: IEEE. *8th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*. [S.l.], 2017. p. 1–5. Citado na página 46.
- SHERSTINSKY, A. Fundamentals of recurrent neural network (rnn) and long short-term memory (lstm) network. *Physica D: Nonlinear Phenomena*, Elsevier, v. 404, p. 132306, 2020. Citado 3 vezes nas páginas 81, 82 e 83.
- SIAMI-NAMINI, S.; TAVAKOLI, N.; NAMIN, A. S. A comparison of arima and lstm in forecasting time series. In: IEEE. *17th IEEE International Conference on Machine Learning and Applications (ICMLA)*. [S.l.], 2018. p. 1394–1401. Citado na página 85.
- SILVA, R. N. F. *et al.* The use of electromechanical impedance based structural health monitoring technique in concrete structures. In: *Proceedings of the 8th European workshop on structural health monitoring*. [S.l.: s.n.], 2016. p. 5–8. Citado 2 vezes nas páginas 30 e 35.
- \_\_\_\_\_. Real-time structural health monitoring method based on the electromechanical impedance approach applied on concrete structures. In: ABCM, COBEM. *24th ABCM International Congress of Mechanical Engineering*. [S.l.], 2017. Citado na página 38.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014. Citado na página 72.
- SINGHA, D. S.; CHOWDARYA, G.; MAHAPATRAA, D. R. Structural damage identification using artificial neural network and synthetic data. *arXiv preprint arXiv:1703.09651*, 2017. Citado na página 38.
- SOH, C. K. *et al.* Performance of smart piezoceramic patches in health monitoring of a rc bridge. *Smart materials and Structures*, IOP Publishing, v. 9, n. 4, p. 533, 2000. Citado na página 35.
- SRIVASTAVA, N. *et al.* Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, JMLR. org, v. 15, n. 1, p. 1929–1958, 2014. Citado 2 vezes nas páginas 61 e 63.

- SUBRAMANIAN, S. *et al.* Towards text generation with adversarially learned neural outlines. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2018. p. 7551–7563. Citado na página 85.
- SULIMAN, A.; ZHANG, Y. A review on back-propagation neural networks in the application of remote sensing image classification. *Journal of Earth Science and Engineering*, v. 5, p. 52–65, 2015. Citado 3 vezes nas páginas 58, 59 e 60.
- SUN, F. *et al.* Truss structure integrity identification using pzt sensor-actuator. *NDT and E International*, v. 5, n. 30, p. 321, 1997. Citado na página 38.
- SUPRATAK, A. *et al.* Deepsleepnet: A model for automatic sleep stage scoring based on raw single-channel eeg. *Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 25, n. 11, p. 1998–2008, 2017. Citado na página 46.
- SUTSKEVER, I.; MARTENS, J.; HINTON, G. E. Generating text with recurrent neural networks. In: *ICML*. [S.l.: s.n.], 2011. p. 1017–1024. Citado na página 85.
- TALAKOKULA, V.; BHALLA, S.; GUPTA, A. Monitoring early hydration of reinforced concrete structures using structural parameters identified by piezo sensors via electromechanical impedance technique. *Mechanical Systems and Signal Processing*, Elsevier, v. 99, p. 129–141, 2018. Citado 2 vezes nas páginas 30 e 35.
- TEBALDI, A. Detecção de falhas estruturais usando sensores e atuadores piezelétricos e algoritmos genéticos. Universidade Estadual Paulista (UNESP), 2004. Citado na página 41.
- TEBALDI, A.; COELHO, L. S.; JUNIOR, V. L. Detecção de falhas em estruturas inteligentes usando otimização por nuvem de partículas: fundamentos e estudo de casos. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, SciELO Brasil, v. 17, p. 312–330, 2006. Citado na página 27.
- TENSORFLOW. *O TensorFlow é uma plataforma completa de código aberto para machine learning*. 2020. Disponível em: <<https://www.tensorflow.org/overview>>. Citado na página 87.
- TSENG, K. K.; NAIDU, A. S. Non-parametric damage detection and characterization using smart piezoceramic material. *Smart Materials and Structures*, IOP Publishing, v. 11, n. 3, p. 317, 2002. Citado na página 40.
- TSURUTA, K. M. *Monitoramento de integridade estrutural de materiais compostos sujeitos a impactos empregando a técnica da impedância eletromecânica*. Dissertação (Mestrado em Engenharia Mecânica) — Faculdade de Engenharia de Mecânica, Universidade Federal de Uberlândia, Uberlândia, 2008. Citado na página 42.
- TSURUTA, K. M. *et al.* Análise da técnica de impedância eletromecânica aplicada no monitoramento de integridade estrutural de estruturas constituídas de materiais compostos. In: *17º Simpósio do Programa de Pós-Graduação em Engenharia Mecânica – POSMEC. FEMEC, Uberlândia*. [S.l.: s.n.], 2007. Citado 4 vezes nas páginas 21, 30, 33 e 35.
- \_\_\_\_\_. Electromechanical impedance-based fault detection in a rotating machine by using an operating condition compensation approach. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *A Tribute Conference Honoring Daniel Inman*. [S.l.], 2017. v. 10172, p. 1017206. Citado 8 vezes nas páginas 28, 30, 35, 36, 88, 104, 105 e 106.

UMESH T., J. *et al.* Structural health monitoring using pzt: A review. *Structural Health Monitoring*, v. 15, p. 16th, 2018. Citado na página 21.

VANDERPLAATS, G. N. *Numerical optimization techniques for engineering design: with applications*. [S.l.]: McGraw-Hill Book Company, New York, 1984. v. 1. Citado na página 59.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: *Proceedings of the xxix conference on graphics, patterns and images*. [S.l.: s.n.], 2016. v. 1, n. 4. Citado na página 77.

VEEN, F. V.; LEIJNEN, S. *The Neural Network Zoo*. *The Asimov Institute*. 2019. Disponível em: <<https://www.asimovinstitute.org/neural-network-zoo>>. Citado na página 22.

WANG, C. *et al.* Pulmonary image classification based on inception-v3 transfer learning model. *IEEE Access*, IEEE, v. 7, p. 146533–146541, 2019. Citado 2 vezes nas páginas 56 e 92.

WANG, J.-H. *et al.* An lstm approach to short text sentiment classification with word embeddings. In: *Proceedings of the 30th conference on computational linguistics and speech processing (ROCLING 2018)*. [S.l.: s.n.], 2018. p. 214–223. Citado na página 85.

WANG, Y. *et al.* The influence of the activation function in a convolution neural network model of facial expression recognition. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 10, n. 5, p. 1897, 2020. Citado 2 vezes nas páginas 54 e 55.

WERBOS, P. J. Generalization of backpropagation with application to a recurrent gas market model. *Neural networks*, Elsevier, v. 1, n. 4, p. 339–356, 1988. Citado na página 80.

WOLLMER, M. *et al.* Feature enhancement by bidirectional lstm networks for conversational speech recognition in highly non-stationary noise. In: IEEE. *International Conference on Acoustics, Speech and Signal Processing*. [S.l.], 2013. p. 6822–6826. Citado na página 83.

WU, J. Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology*. *Nanjing University*. *China*, v. 5, p. 23, 2017. Citado na página 75.

YADAV, S. S.; JADHAV, S. M. Deep convolutional neural network based medical image classification for disease diagnosis. *Journal of Big Data*, Springer, v. 6, n. 1, p. 113, 2019. Citado na página 72.

YAMASHITA, R. *et al.* Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, Springer, v. 9, n. 4, p. 611–629, 2018. Citado 2 vezes nas páginas 68 e 72.

YAN, S. *Understanding LSTM and its Diagrams*. *ML Review: Machine Learning Research, Projects and Educational Materials*. 2016. Disponível em: <<https://medium.com/mlreview/understanding-lstm-and-its-diagrams-37e2f46f1714>>. Citado na página 84.

YU, W. *et al.* Learning deep representations via extreme learning machines. *Neurocomputing*, Elsevier, v. 149, p. 308–315, 2015. Citado 2 vezes nas páginas 47 e 58.

ZHAI, S. *et al.* Doubly convolutional neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2016. p. 1082–1090. Citado na página 67.

ZHANG, B. *et al.* Alphamex: A smarter global pooling method for convolutional neural networks. *Neurocomputing*, Elsevier, v. 321, p. 36–48, 2018. Citado na página 75.

ZHANG, J. *et al.* An improved long short-term memory model for dam displacement prediction. *Mathematical Problems in Engineering*, Hindawi, v. 2019, 2019. Citado 3 vezes nas páginas 80, 81 e 83.

ZHANG, S.; YU, F. Piezoelectric materials for high temperature sensors. *Journal of the American Ceramic Society*, Wiley Online Library, v. 94, n. 10, p. 3153–3170, 2011. Citado na página 28.

ZHAO, H. *et al.* Loss functions for image restoration with neural networks. *Transactions on computational imaging*, IEEE, v. 3, n. 1, p. 47–57, 2016. Citado 2 vezes nas páginas 58 e 83.

ZHAO, J. Nn-adaptive predictive control for a class of discrete-time nonlinear systems with input-delay. *Neurocomputing*, Elsevier, v. 173, p. 1832–1838, 2016. Citado 4 vezes nas páginas 79, 82, 83 e 85.

ZHAO, R. *et al.* Machine health monitoring with lstm networks. In: IEEE. *10th International Conference on Sensing Technology (ICST)*. [S.l.], 2016. p. 1–6. Citado na página 80.