

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA
CURSO DE ENGENHARIA MECÂNICA

PLÍNIO ANTÔNIO DE MORAES NETO

**USO DE *AUTOENCODERS* PARA REMOÇÃO DE RUÍDO EM IMAGENS
TERMOGRÁFICAS**

TRABALHO DE CONCLUSÃO DE CURSO

UBERLÂNDIA

2023

PLÍNIO ANTÔNIO DE MORAES NETO

**USO DE *AUTOENCODERS* PARA REMOÇÃO DE RUÍDO EM IMAGENS
TERMOGRÁFICAS**

Trabalho de Conclusão de Curso apresentado ao Curso de
Engenharia Mecânica da Universidade Federal de
Uberlândia, como requisito parcial para a obtenção do
título de Bacharel em Engenharia Mecânica.

Orientador: Henrique Coelho Fernandes

UBERLÂNDIA

2023

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

M827
2023 Moraes Neto, Plinio Antonio de, 1999-
Uso de autoencoders para remoção de ruído de imagens
termográficas [recurso eletrônico] / Plinio Antonio de
Moraes Neto. - 2023.

Orientador: Henrique Coelho Fernandes.
Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Uberlândia, Graduação em
Engenharia Mecânica.

Modo de acesso: Internet.

Inclui bibliografia.

Inclui ilustrações.

1. Engenharia mecânica. I. Fernandes, Henrique
Coelho, 1986-, (Orient.). II. Universidade Federal de
Uberlândia. Graduação em Engenharia Mecânica. III.
Título.

CDU: 621

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074

PLÍNIO ANTÔNIO DE MORAES NETO

USO DE *AUTOENCODERS* PARA REMOÇÃO DE RUÍDO DE IMAGENS
TÉROGRÁFICAS

Trabalho de Conclusão de Curso apresentado ao Curso de
Engenharia Mecânica da Universidade Federal de
Uberlândia, como requisito parcial para a obtenção
do título de Bacharel em Engenharia Mecânica.

Uberlândia, 10/07/2023

Banca Examinadora:

Henrique Coelho Fernandes – Prof. Dr. (UFU)

Jefferson Gomes do Nascimento – Dr. (UFU)

AGRADECIMENTOS

Gostaria de agradecer à minha família pelo apoio, suporte e estrutura necessários à conclusão dessa etapa. À Universidade Federal de Uberlândia (UFU) e à Faculdade de Engenharia Mecânica (FEMEC) por fornecerem estrutura e recursos de qualidade, além de fomentar a curiosidade e incentivar a procura pelo conhecimento. Agradeço ao corpo docente, que me deu a oportunidade de absorver seus conhecimentos e consolidar os meus. Especialmente ao professor Henrique, que me orientou e facilitou o processo de conclusão do projeto de fim de curso. À Júlia, pelo carinho e apoio durante os últimos quatro anos. Além disso, não poderia deixar de agradecer aos colegas Marcus Filipe Sousa Reis e Cayo Magno da Cruz Fontana, que me auxiliaram na finalização do trabalho.

RESUMO

MORAES, P. Uso de *autoencoders* para remoção de ruído em imagens termográficas. 2023. 32f. Projeto Final de Curso – Curso de Engenharia Mecânica, Universidade Federal de Uberlândia. UBERLÂNDIA, 2023

Ensaio não destrutivo é uma das ferramentas que permite a aferição do bom funcionamento de equipamentos, além da qualidade dos materiais empregados neles. Permitem que seja feito o monitoramento de componentes sem que haja qualquer dano a eles. Dentre as várias técnicas utilizadas nesse processo, tem-se a termografia infravermelha, que permite mapear um corpo baseando-se na distribuição de calor. Neste trabalho, foi realizado um tratamento de imagens termográficas, de modo a tratar possíveis ruídos que surgem durante a etapa de obtenção dos termogramas. Para realizar essa tarefa, foi utilizada uma autoencoder baseada em uma CNN, que tem o papel de coletar os atributos da imagem e reconstruí-la sem o ruído. Foi provado que as redes neurais têm um grande potencial de redução de ruído em imagens, porém sua arquitetura deve ser mais robusta, de modo a não haver grandes perdas de informação nas imagens.

Palavras-chave: termografia, redes neurais, *autoencoders*, transferência de calor, tratamento de imagens, microbolômetro, ensaios não destrutivos.

ABSTRACT

MORAES, P. Use of autoencoders in noise removal in thermal images. 2023. 32p. Undergraduate Final Project – Mechanical Engineering Course, Universidade Federal de Uberlândia. UBERLÂNDIA, 2023

Non-destructive testing is one of the tools that allows the assessment of the proper functioning of equipment, as well as the quality of the materials used in them. It allows the monitoring of components without causing any damage to them. Among the various techniques used in this process, is infrared thermography, which allows the mapping of a body based on heat distribution. In this work, processing of thermographic images was carried out in order to treat possible noise that arises during the stage of obtaining the thermograms. To perform this task, an autoencoder based on a CNN was used, which has the role of collecting the attributes of the image and reconstructing it without the noise. It was proven that neural networks have a great potential to reduce noise in images, but their architecture must be more robust so that there is no great loss of information in the images.

Key words: thermography, neural networks, autoencoders, heat transfer, image processing, microbolometer, non-destructive testing.

LISTA DE ABREVIATURAS E SIGLAS

END – Ensaios Não Destrutivos

IRT – Infrared Thermography (Termografia Infravermelha)

DL – Deep Learning (Aprendizagem Profunda)

ML – Machine Learning (Aprendizagem de Máquinas)

ANN – Artificial Neural Networks (Redes Neurais Artificiais)

RNN – Recurrent Neural Networks (Redes Neurais Recorrentes)

CNN – Convolutional Neural Networks (Redes Neurais Convolucionais)

PT – Pulsed Thermography (Termografia Pulsada)

LISTA DE TABELAS

Tabela 1: Análise de resultados do experimento com o banco de dados MNIST	23
Tabela 2: Arquitetura da CNN.....	26
Tabela 3: Análise de resultados da remoção de ruído das imagens térmicas	27

LISTA DE FIGURAS

Figura 1 - Infravermelho (IR) e regiões espectrais adjacentes e vista ampliada do chamado infravermelho térmico. Esta é a região onde existem sistemas de imagem IR para câmeras de onda curta (SW), onda média (MW), ou onda longa (LW). Sistemas especiais têm faixas de MW ou SW estendidas.	13
Figura 2 - Classificação de objetos de acordo com a emissividade e comprimento de onda ...	14
Figura 3 - Intercepção de irradiação espectral por um meio semitransparente	15
Figura 4 - Comparativo esquemático da distribuição de temperatura na presença de um defeito interno.....	16
Figura 5 - Treinamento típico de um modelo de Machine Learning.....	17
Figura 6 - Arquitetura básica de uma rede neural	19
Figura 7 - Estrutura de uma autoencoder.....	20
Figura 8 - Esquema representativo de uma denoising autoencoder	21
Figura 9 - Banco de dados MNIST.....	22
Figura 10 - Comparativo entre imagens originais, com ruído e tratadas.....	22
Figura 11 – Posição dos insertos artificiais nas camadas do laminado	23
Figura 12 - Setup do experimento de captura das imagens térmicas.....	24
Figura 13 - Comparação entre imagens originais e com ruído gaussiano adicionado	25
Figura 14 - Representação esquemática da arquitetura da autoencoder	27
Figura 15 - Comparação das imagens originais com as ruidosas e o output do modelo	28
Figura 16: Análise dos valores de entropia cruzada (a) e erro (b) ao longo das épocas.....	29

LISTA DE SÍMBOLOS

ε – Emissividade

λ – Comprimento de Onda

α – Absortividade

ρ – Refletividade

τ – Transmissividade

μ – Média

σ – Desvio Padrão

SUMÁRIO

1. INTRODUÇÃO	13
2. REFERENCIAL TEÓRICO	13
2.1. TERMOGRAFIA INFRAVERMELHA	13
2.2. APRENDIZAGEM PROFUNDA (<i>DEEP LEARNING</i>)	16
3. METODOLOGIA	21
3.1. EXPERIMENTOS INICIAIS	21
3.1.1. RESULTADOS DO EXPERIMENTO	23
3.2. OBTENÇÃO DAS IMAGENS TÉRMICAS	23
3.2.1. TRATAMENTO DOS DADOS TERMOGRÁFICOS	24
3.3. ARQUITETURA DA CNN	25
4. RESULTADOS.....	27
5. CONCLUSÃO	29
REFERÊNCIAS BIBLIOGRÁFICAS	30

1. INTRODUÇÃO

Existem diversas maneiras de verificar a integridade e existência de defeitos no interior de uma peça, porém, grande maioria deles envolve mudança de propriedade físico-químicas, mecânicas ou dimensionais desse componente, o que a inutiliza. A fim de evitar esses danos, os ensaios não destrutivos (END) passaram a ser empregados.

Podem ser utilizadas diversas técnicas em END que abrangem desde aplicação de líquido penetrante, ultrassom, partículas magnéticas, termografia infravermelha e raio X. A escolha do método mais adequado varia, principalmente, do material sendo testado, localização do defeito e custos.

Dentre as diversas técnicas de ensaios não destrutivos, destaca-se a termografia infravermelha, que utiliza a distribuição de calor no corpo para verificar se existe algum defeito no componente. O calor se comportará diferente em defeitos e no material da peça, o que possibilita a visualização deles nas imagens termográficas.

No entanto, durante a captura das imagens termográficas, alguns fatores como altas temperaturas e má iluminação, podem gerar ruídos que impedem a visualização dos defeitos na peça. Dessa maneira, faz-se necessário a aplicação de um método de tratamento das imagens.

Neste trabalho, será feito um estudo utilizando *autoencoders* baseadas em redes neurais convolucionais, a fim de reconstruir os termogramas sem ruído, porém mantendo seus atributos. As imagens utilizadas foram obtidas durante a execução do doutorado do Prof. Dr. Henrique Coelho Fernandes na Université Laval. A elas será adicionado um ruído gaussiano artificial, de modo a simular um experimento real e que, posteriormente, será tratado pela *autoencoder*.

2. REFERENCIAL TEÓRICO

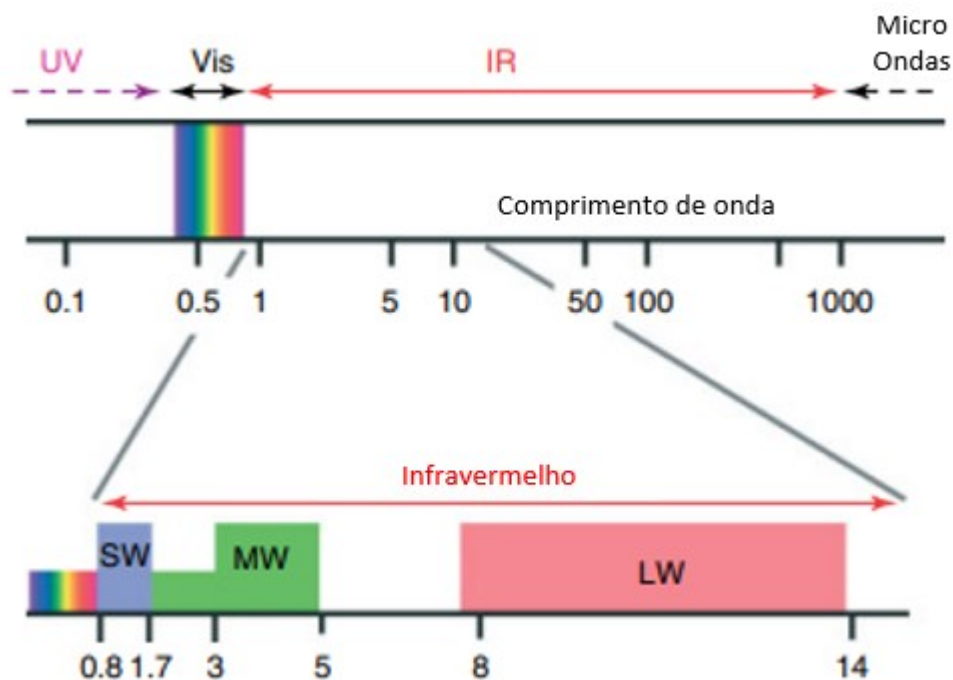
O referencial teórico deste trabalho foi dividido em dois tópicos. O primeiro acerca da termografia infravermelha e, posteriormente, aprendizagem profunda e *autoencoders*.

2.1. TERMOGRAFIA INFRAVERMELHA

A termografia infravermelha (IRT) é uma das várias técnicas de ensaios não destrutivos aplicadas na indústria de detecção de falhas em materiais e componentes. Essa se baseia na detecção e interpretação da radiação infravermelha emitida pelo corpo de teste utilizando uma câmera. É extremamente vantajoso utilizar a IRT nessas aplicações, visto que não é nociva para o ser humano, além de ser relativamente fácil de se realizar as capturas das imagens termográficas, também conhecidas como termogramas.

A radiação infravermelha foi descoberta no início do século XIX, enquanto a primeira câmera sensível à radiação infravermelha foi criada no início do século. No passado, era utilizada uma composição com um detector infravermelho e alguns espelhos para gerar a imagem. Os equipamentos atuais são compostos de um sensor infravermelho, *hardware* de análise de imagem e um monitor de visualização em tempo real (KHAKSARI *et al.*,2021).

Figura 1 - Infravermelho (IR) e regiões espectrais adjacentes e vista ampliada do chamado infravermelho térmico. Esta é a região onde existem sistemas de imagem IR para câmeras de onda curta (SW), onda média (MW), ou onda longa (LW). Sistemas especiais têm faixas de MW ou SW estendidas.



Fonte: Fundamentals of Thermal Imaging, 2017 (p. 10) (modificado)

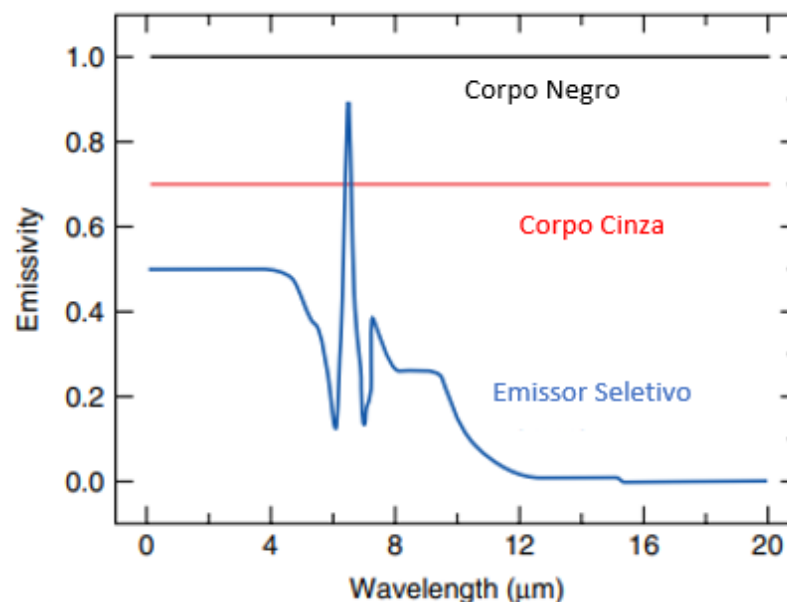
As câmeras utilizadas para capturar as imagens variam conforme a aplicação. Podem variar quanto à resolução, sensibilidade de temperatura, taxa máxima de quadros e qualidade da imagem gerada, além do aumento de custo inerente à melhoria desses fatores.

A utilização adequada das câmeras depende de uma boa calibração, que é feita tomando como base o corpo negro. Esse é conhecido como um “emissor perfeito”, pois absorvem toda a radiação incidente (emissividade (ϵ) igual a 1), independentemente do comprimento de onda e direção (MALDAGUE, 2001). Eles são utilizados para a calibração pois, a diferentes temperaturas, suas quantidades radiométricas, como excitância (M) e radiância (L) são bem definidas. Portanto, é possível criar uma relação entre o sinal da câmera e a temperatura do corpo negro (VOLLMER, MÖLLMANN, 2017).

A emissividade (ϵ) é definida como a proporção da quantidade de radiação emitida da superfície em relação àquela emitida por um corpo negro na mesma temperatura. Em termos práticos, é a capacidade de uma superfície de emitir energia. Existem diversas variáveis que afetam o valor da emissividade. Entre eles, deve-se destacar: material, acabamento superficial, geometria, direção de observação, comprimento de onda e temperatura. A emissividade também é utilizada como parâmetro para classificação de objetos (Figura 2):

- 1- **Corpo Negro:** $\epsilon = 1$, invariável
- 2- **Corpo Cinza:** $\epsilon = 1$, invariável em relação a comprimento de onda (λ)
- 3- **Emissor Seletivo:** $0 < \epsilon < 1$, varia conforme o comprimento de onda.

Figura 2 - Classificação de objetos de acordo com a emissividade e comprimento de onda



Na grande maioria das aplicações de termografia, são analisados corpos cinzas, em que $\varepsilon(\lambda, T)$ é uma constante.

A emissividade pode ser deduzida a partir da Lei de Kirchhoff, que constata que toda a energia absorvida por um corpo é igual àquela emitida por ele (VOLLMER, MÖLLMANN, 2017). Essa relação pode ser descrita pela Equação 1, em que α é a absortividade. Além dela, também são consideradas a refletividade (ρ) e a transmissividade (τ).

$$\varepsilon = \alpha \quad (1)$$

Absortividade (α): Relaciona a quantidade de energia emitida sobre a superfície com a quantidade absorvida por ela.


Refletividade (ρ): Define qual a fração de energia irradiada que é refletida para o ambiente. É definida pela direção da energia incidente (θ) e direção de energia refletida (θ').

Transmissividade (τ): Esse conceito representa a capacidade do corpo de transmitir a energia. É calculado pela razão entre a quantidade transmitida por ele sobre a quantidade irradiada sobre ele.

Tomando como base a lei da conservação de energia, a soma desses três fatores é igual a 1 (Equação 2). Essa relação está representada esquematicamente pela Figura 3.

$$\alpha + \rho + \tau = 1 \quad (2)$$

Figura 3 - Intercepção de irradiação espectral por um meio semitransparente




Fonte: Infrared Thermometry Theory and Applications with Arduino and Python (2019) (modificado).

A detecção de defeitos na termografia é baseada na distribuição de temperatura na superfície. Com diferentes formas de excitação térmica ativa, a estrutura heteromórfica do objeto pode ser representada pela distribuição da temperatura superficial, de forma que o defeito pode ser localizado e identificado com precisão (QU, JIANG, ZHANG, 2020).

Dentre as técnicas de excitação térmica, a que se destaca é a termografia pulsada, em que se usa uma fonte de calor para aquecer a superfície, enquanto a câmera infravermelha é utilizada para capturar as imagens da distribuição de temperatura. Existem várias fontes que podem ser usadas, como um flash de alta potência, laser, lâmpada ou ar quente. A escolha delas depende de fatores como profundidade de detecção do defeito, material da superfície e volume. A grande vantagem da termografia pulsada é a velocidade e alta eficiência do método, além de ser simples. No entanto, não é adequada para detecção de falhas em peças com geometria complexa, apenas para superfícies planas. Além disso, a profundidade de detecção é baixa, quando comparada a outros métodos.

A presença de defeitos na superfície acarreta numa descontinuidade na imagem térmica, uma vez que esses interagem com o calor de forma diferente ao material da peça, o que permite identificá-los. A diferença é ilustrada na Figura 4.

Figura 4 - Comparativo esquemático da distribuição de temperatura na presença de um defeito interno



Fonte: Development and application of infrared thermography non-destructive testing techniques (2020) (modificado)


2.2. APRENDIZAGEM PROFUNDA (*DEEP LEARNING*)

Deep Learning (DL) é uma subárea de *Machine Learning* (ML - Aprendizagem de máquina), em que se usa redes neurais com múltiplas camadas para encontrar soluções para

diversos problemas. A aplicação de DL tem revolucionado áreas como a detecção de câncer, carros autônomos, processamento de linguagem natural e processamento de imagens.

Machine Learning trata de modelos baseados em algoritmos que aprendem com a experiência. À maneira que um modelo adquire mais experiência, ou em outras palavras, mais dados, seus resultados tendem a melhorar (ZHANG *et al*, 2021). Esse processo de coleta de dados e aprendizado é chamado de treinamento. Ele é representado esquematicamente pela Figura 5.

Figura 5 - Treinamento típico de um modelo de *Machine Learning*



Fonte: Dive Into Deep Learning (2021) (modificado).

Em ML, existem quatro tipos de métodos de aprendizado: supervisionado, não-supervisionado, semi-supervisionado e aprendizado de reforço.

Aprendizado Supervisionado

Nesse método, o objetivo é prever o resultado de uma variável (chamada de *target*) com variáveis conhecidas (*features*). O modelo utiliza as relações entre elas para chegar em um algoritmo que pode ser replicado em dados de teste e, posteriormente, em maior escala. A performance desse método é avaliada comparando os resultados do *dataset* de treinamento e o de validação.

Aprendizado Não Supervisionado

O aprendizado não-supervisionado procura detectar padrões num *dataset* e categorizar instâncias desse nessas categorias. Esse método recebe esse nome pois os padrões (que podem ou não existir) não são fornecidos pelo *target* e são determinados pelo algoritmo. (CHOI *et al*, 2020). Os principais problemas tratados por aprendizado não supervisionado são agrupamento (clusterização), associação ou detecção de anomalias.

Aprendizado Semi-supervisionado

Pode ser entendido como um intermediário entre os métodos supervisionados e não supervisionados e é útil em *datasets* em que parte dos dados que não foram categorizados. É muito usado em situações que se deseja rotular imagens médicas, no qual o médico faz esse processo manualmente em um subconjunto de imagens e treina um modelo para realizar a categorização das imagens automaticamente (CHOI *et al*, 2020).

Aprendizado de Reforço


Neste método, entende-se que o algoritmo aprenderá da própria experiência, procurando sempre otimizar o processo de tomada de decisão. Ele tentará explorar caminhos que podem ou não levar à resposta e então aprender com eles para que numa próxima tentativa de solucionar aquele problema, decisões incorretas já exploradas não sejam tomadas novamente. Pode ser aplicado ao treinar uma inteligência artificial (IA) para jogar xadrez com um mestre e ela se adaptar à maneira que a pessoa toma as decisões dentro do jogo. Além disso pode ser aplicado nos campos da robótica, carros autônomos, entre outros. (FRANÇOIS-LAVET *et al*, 2018)

Entre os algoritmos mais famosos utilizados em ML estão as regressões lineares, regressões logísticas, árvores de decisão e, por fim, as redes neurais artificiais (ANN), que serão tratadas com maior profundidade neste trabalho.

Redes neurais são algoritmos que procuram se assemelhar às conexões feitas no cérebro humano e procura modelar a maneira que como o órgão realiza uma tarefa específica. (HAYKIN, S, 2001). Elas são compostas por camadas e a distribuição e arranjo dessas é conhecido como a arquitetura da ANN.

A arquitetura básica de uma rede neural é formada por uma camada de entrada (*input*), uma camada de saída (*output*) e camadas intermediárias, também chamadas de camadas ocultas (Figura 6). Essas camadas são formadas por nós e as conexões entre eles possuem pesos e limites associados. Esses são responsáveis por definir quais nós da próxima camada serão ativados, a fim de atingir uma resposta adequada.

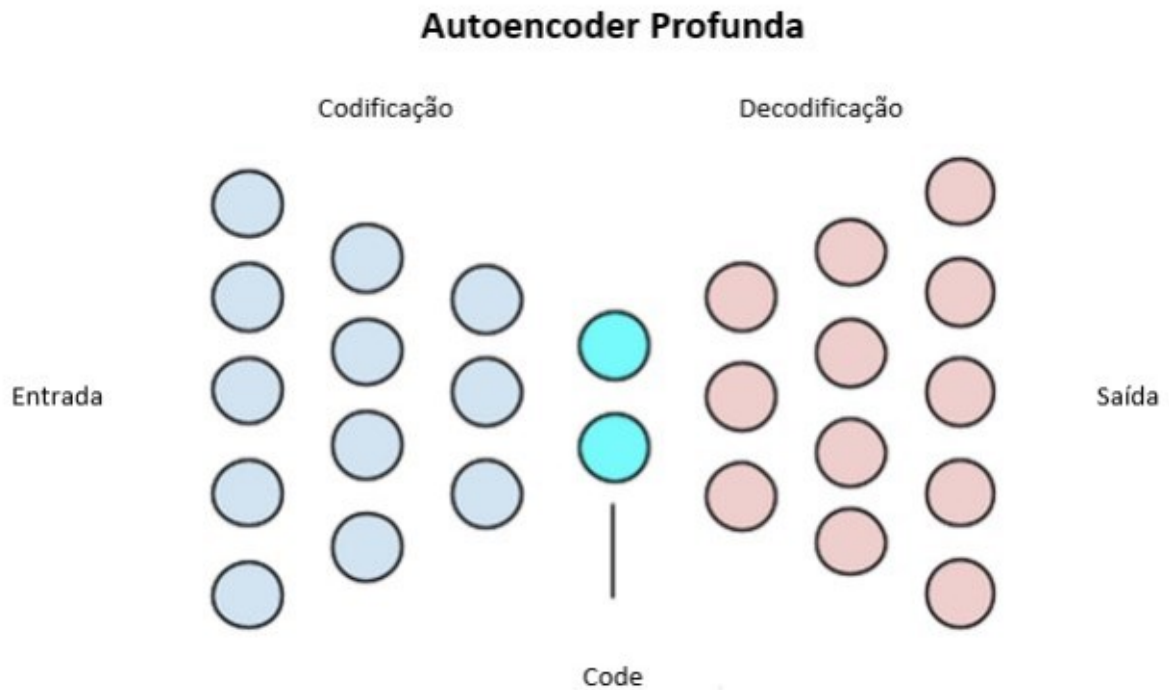
Figura 6 - Arquitetura básica de uma rede neural



Fonte: IBM Cloud Learn Hub (2020) < <https://www.ibm.com/br-pt/cloud/learn/neural-networks> > (modificado)

Os modelos baseados em regressão linear são amplamente aplicados em ML, porém possuem algumas limitações. Uma maneira de ultrapassar essas dificuldades é a utilização de redes neurais profundas. No entanto, existem diversas maneiras, com diferentes aplicações, em que essas camadas podem ser arquitetadas, como as redes neurais convolucionais (CNN), que têm grandes aplicações na área de visão computacional, as redes neurais recorrentes (RNN) e as *autoencoders*.

A *autoencoder* é uma técnica de aprendizado não supervisionado, que tem como objetivo comprimir e representar os dados de entrada de forma significativa (BANK *et al*, 2020). A estrutura dessa rede neural é formada por duas redes simétricas, com um gargalo no centro. A ideia é um processo de codificação, no qual se comprime a entrada e coleta as informações mais importantes, a versão comprimida recebe o nome de *code*. Seguido pela etapa de *decoding*, na qual é feita a reconstrução dos dados. A estrutura é apresentada na Figura 7.

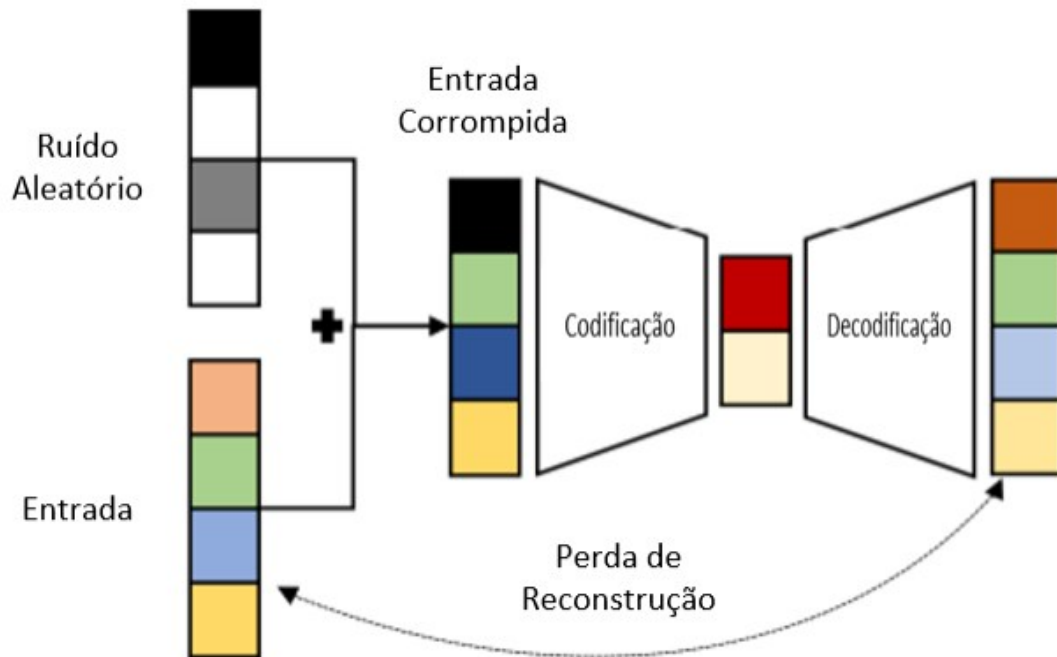
Figura 7 - Estrutura de uma *autoencoder*

Fonte: Deep Learning Book, Data Science Academy (2022) (modificado)

As *autoencoders*, no geral, apresentam o centro menor para que se tenha uma representação de dimensões reduzidas dos dados de entrada. Isso pode ser importante para realizar tarefas como compressão de dados e extração de atributos principais. Geralmente, esse gargalo é de dimensões menores que a camada de entrada, de modo a evitar o risco de o algoritmo apenas replicar os dados de *input*. Quando isso ocorre, a rede neural tem um baixo desempenho ao realizar a tarefa desejada em novos dados, uma vez que ela “decorou” o processo para os dados de *input*.

Uma aplicação muito utilizada desse algoritmo é a *denoising autoencoder*, que geralmente é utilizada para a reconstrução dos dados de entrada com a remoção de defeitos e ruídos (PASCAL *et al*, 2010). Nesses casos, a intenção é coletar o máximo de informações relevantes possível, e utilizá-las para reconstruir o *input* sem o ruído e com perda mínima de atributos importantes dos dados. Um esquema que representa o processo de *denoising* está na Figura 8.

Figura 8 - Esquema representativo de uma *denoising autoencoder*



Fonte: Autoencoders, 2018 (modificado)

Este trabalho tem por objetivo a redução de ruído e melhoramento geral de qualidade de imagens termográficas geradas por um microbolômetro. No entanto, tendo em vista o alto custo de equipamentos de termografia mais sofisticados, fez-se necessário a utilização de software, neste caso, as *denoising autoencoders*, para realizar essa tarefa.


3. METODOLOGIA

Primeiramente, foram feitos testes com as *denoising autoencoders* em imagens mais simples, a fim de entender o comportamento delas, para então aplicá-las nas imagens térmicas, que são mais complexas.

3.1. EXPERIMENTOS INICIAIS

Foram realizados ensaios experimentais com *autoencoders* utilizando bases de dados já consolidadas e validadas. Neste caso foi utilizado o banco de imagens MNIST (Figura 9), que é constituído de 60000 imagens de dígitos manuscritos no formato 28x28 pixels. A *database* é amplamente usada para preparação e teste de modelos no campo de *machine learning*.

Figura 9 - Banco de dados MNIST




Fonte: Cohen, G., Afshar, S., Tapson, J., & van Schaik, A. (2017). EMNIST: an extension of MNIST to handwritten letters. Retrieved from <http://arxiv.org/abs/1702.05373>

Nesse experimento, foi adicionado ruído gaussiano artificial, cuja função densidade-probabilidade de uma variável aleatória z é representada pela Equação 3. O objetivo desse experimento é que a *autoencoder* reconstrua a imagem sem o ruído, com o mínimo de informação perdida nesse processo. Dessa maneira, o *input* do modelo são as imagens ruidosas e o *output* são as imagens “limpas”.

$$p_G(z) = \frac{1}{\sigma\sqrt{2\pi}} * e^{-\frac{(z-\mu)^2}{2\sigma^2}} \quad (3)$$

Dentre os vários tipos de ruídos disponíveis, foi selecionado o ruído gaussiano visto que é o mais comum durante a aquisição das imagens. Esse pode surgir com altas temperaturas, má iluminação, entre outros. (KUMAR, A., SODHI, S., 2020)

Figura 10 - Comparativo entre imagens originais, com ruído e tratadas



3.1.1. RESULTADOS DO EXPERIMENTO

Percebe-se algumas diferenças que aparecem no resultado, porém, qualitativamente, é visível a capacidade do algoritmo de realizar a tarefa de remoção de ruído. Quantitativamente, é possível verificar as métricas utilizadas na etapa de validação para análise na Tabela 1.

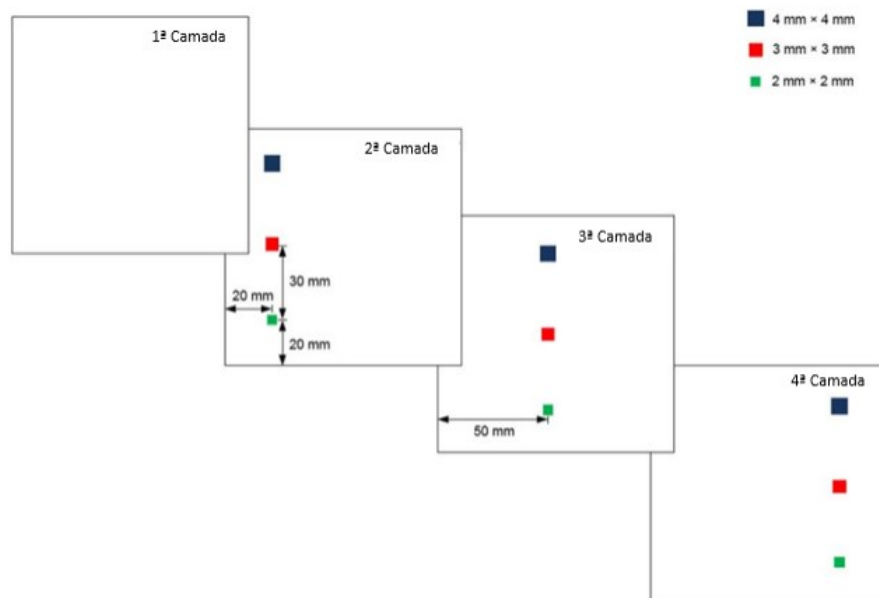
Tabela 1: Análise de resultados do experimento com o banco de dados MNIST

Métrica	Valor
Entropia Cruzada	0.0981
Erro Quadrático Médio	0.0117
Erro Absoluto Médio	0.0377

3.2. OBTENÇÃO DAS IMAGENS TÉRMICAS

No experimento, utiliza-se um material compósito com insertos artificiais colocados nas camadas do laminado (Figura 11). A parte do material que foi inspecionada é uma placa 100 × 100 mm feita com carbono/Poly-Ether-Ketone (PEEK) reforçada com Randomly-Oriented Unidirectional Strands (ROS) (FERNANDES, 2015).

Figura 11 – Posição dos insertos artificiais nas camadas do laminado



Fonte: Carbon fiber composite inspection and defect characterization using active infrared thermography: numerical simulations and experimental results (2016) (modificado).

Com a amostra preparada, foi feita a montagem do experimento de termografia pulsada (PT). Como fonte de calor, foram utilizados dois flashes fotográficos com duração de pulso de 5 milissegundos e 6,4 kJ por flash. Para a realização das capturas, foi utilizada a câmera infravermelha FLIR Phoenix, InSb, com comprimento espectral de 3 – 5 μm , que gera imagens de 640 \times 512 pixels, a uma taxa de quadros de 55 Hz.

Figura 12 - Setup do experimento de captura das imagens térmicas



Fonte: Fiber orientation analysis of carbon fiber-reinforced polymers by infrared thermography. (2015)

De um experimento de termografia pulsada, foram geradas 1385 imagens do fenômeno transiente, que foram tratadas e aplicadas ao modelo de CNN.

3.2.1. TRATAMENTO DOS DADOS TERMOGRÁFICOS

A. Tamanho

As imagens geradas têm dimensão 421 \times 416 pixels, o que gera um custo computacional muito grande ao ser tratada pela *autoencoder*. Portanto, a primeira etapa de tratamento dos dados foi modificar o tamanho das imagens para 128 \times 128 pixels.

B. Normalização dos dados


As temperaturas no dataset variam de 24.8649 a 80.8721, o que pode gerar erros na reconstrução. Dessa maneira, deve ser feita uma normalização dos dados, de forma que os pontos estejam na mesma escala. Nesse caso, foi utilizado a Normalização MinMax, que é representada pela Equação 4.

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (4)$$

C. Adição de ruído

Por fim, assim como no experimento com o banco de dados MNIST, o *input* da CNN é a imagem ruidosa. Portanto, foi adicionado o ruído gaussiano às imagens térmicas, os resultados são apresentados na Figura 13.

Figura 13 - Comparação entre imagens originais e com ruído gaussiano adicionado



3.3. ARQUITETURA DA CNN

As redes neurais convolucionais (CNN) são muito utilizadas em problemas de ML e DL em que o dataset é formado por imagens. Essas redes podem apresentar diversas estruturas, com variadas quantidades e composições de camadas, a depender do problema em foco. Neste trabalho, foram utilizados os seguintes tipos de camadas:

Input: É a camada em que a imagem ruidosa entra no modelo.

Convolucionais: Essa camada é responsável por coletar os atributos da imagem. A operação matemática de convolução é realizada entre a imagem de entrada e um filtro (kernel) de um determinado tamanho $M \times M$. Ao passar o filtro sobre a imagem de entrada, o produto escalar é obtido entre o filtro e as partes da imagem de entrada com relação ao tamanho do filtro ($M \times M$).


Pooling: Tem a função de reduzir a dimensão do mapa de atributos criado pela camada de convolução, a fim de reduzir custos computacionais. Existem operações através das quais o *pooling* pode ser realizado. Neste trabalho, foi utilizada a MaxPooling, em que o maior valor do mapa de atributos é usado na redução da dimensão.

Upsampling: Essa camada é responsável por aumentar as dimensões dos dados. Após a etapa de *encoding*, é necessário que seja feito esse aumento para que a saída do modelo tenha as mesmas dimensões da entrada. Esse processo é feito através de uma interpolação dos valores dos pixels vizinhos.

Para a remoção de ruído das imagens térmicas, foi utilizada a mesma arquitetura da rede do experimento com o banco de dados MNIST. Ela está apresentada na Tabela 2 e esquematicamente na Figura 14.

Tabela 2 - Arquitetura da CNN

Camada (Tipo)	Output (Formato)
Input Layer	[(None, 128,128,1)]
Conv2D	[(None, 128,128,32)]
MaxPooling2D	[(None, 64,64,32)]
Conv2D	[(None, 64,64,32)]
MaxPooling2D	[(None, 32,32,32)]
Conv2D	[(None, 32,32,32)]
UpSampling2D	[(None, 64,64,32)]
Conv2D	[(None, 64,64,32)]
UpSampling2D	[(None, 128,128,32)]
Conv2D	[(None, 128,128,1)]

Figura 14 - Representação esquemática da arquitetura da *autoencoder*

4. RESULTADOS

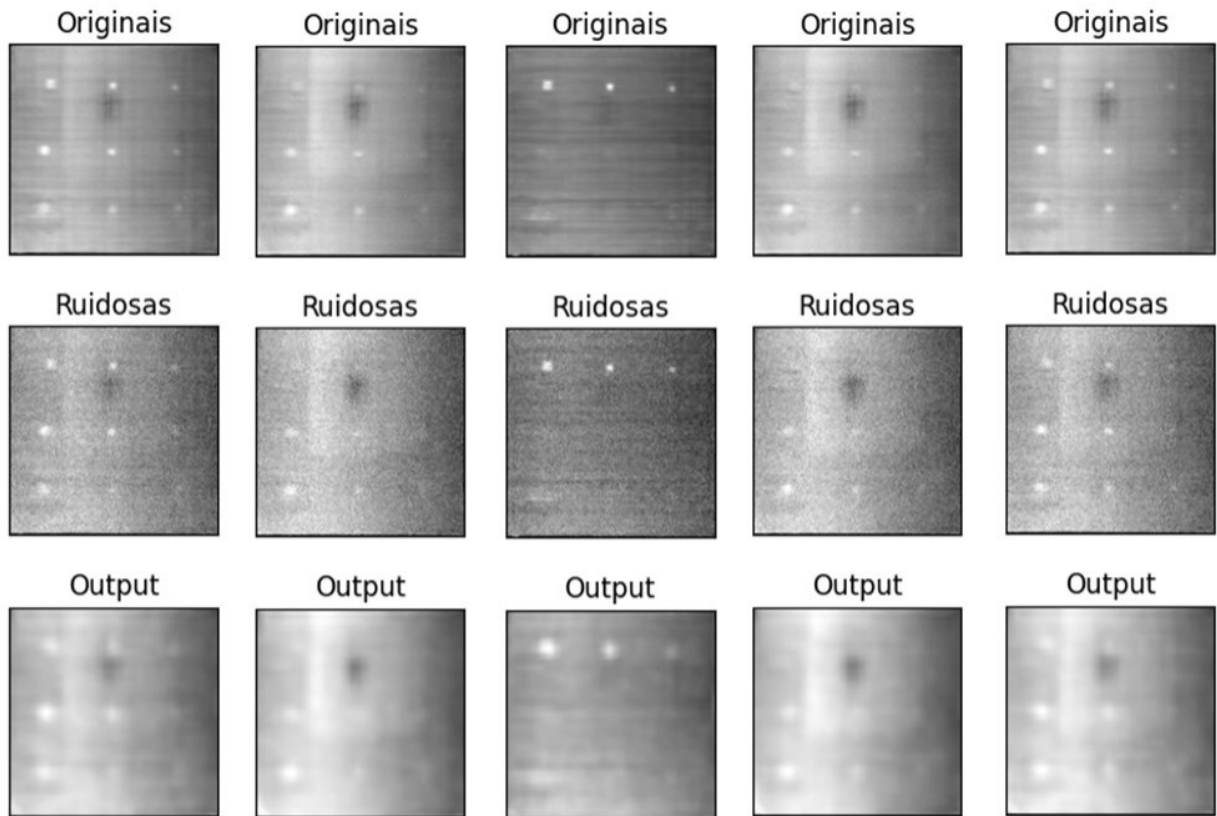
Para a análise dos resultados, foram mostradas 5 imagens do *dataset* e comparadas às imagens ruidosas e às tratadas pela rede neural. Os resultados quantitativos são apresentados na Tabela 3.

Tabela 3 - Análise de resultados da remoção de ruído das imagens térmicas

Métrica	Valor
Entropia Cruzada	0.5939
Erro Quadrático Médio	3.2492×10^{-4}
Erro Absoluto Médio	0.0139

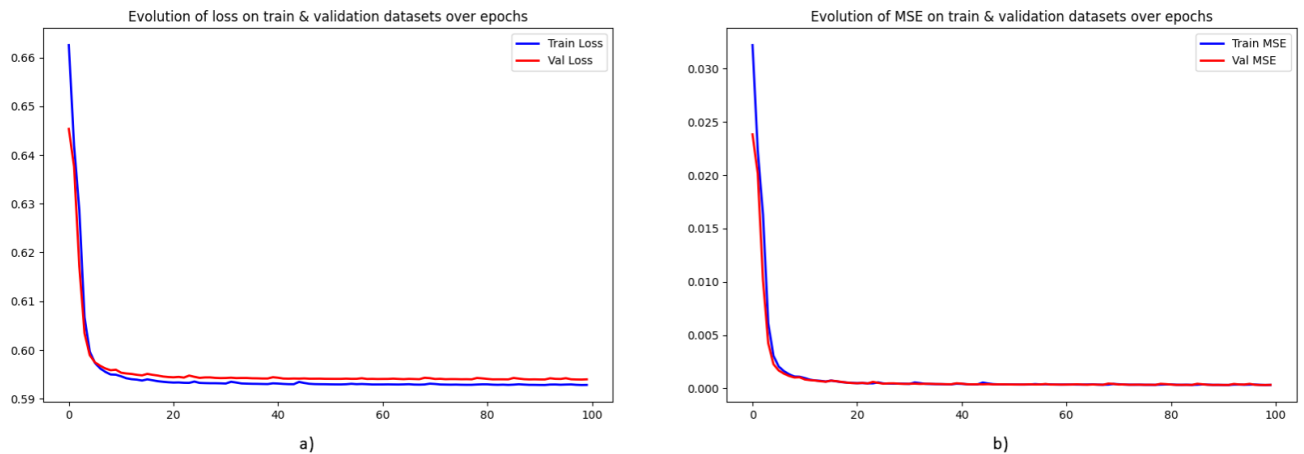
Visualmente, percebe-se que a remoção de ruído é bem-sucedida, porém também se perde algumas informações da imagem original. Apesar desta perda, ainda é possível visualizar as descontinuidades dentro da peça, o que é positivo. Os resultados se assemelham àqueles de um filtro Gaussiano, que gera um desfoque da imagem, de modo a se reduzir o efeito de distorção causado pelo ruído. Os resultados estão na Figura 15.

Figura 15 - Comparação das imagens originais com as ruidosas e o output do modelo



Por fim, na Figura 16, são apresentados os gráficos de evolução dos valores entropia cruzada e erro quadrático médio ao longo das épocas na etapa de validação. Eles apontam que à maneira que a rede adquire as informações das imagens, esses valores diminuem, o que é o comportamento adequado.

Figura 16: Análise dos valores de entropia cruzada (a) e erro (b) ao longo das épocas



As imagens do experimento (MNIST) são simples, possuem, basicamente, valores binários e têm tamanho de 28×28 pixels. Já as imagens termográficas possuem um nível de detalhe maior e passaram por um redimensionamento devido ao custo computacional, o que causa uma perda de informações. Dessa maneira, ao se utilizar a mesma arquitetura da rede neural para esses dois problemas, o resultado é inferior no segundo caso.

5. CONCLUSÃO

Através dos resultados encontrados, percebe-se que as *autoencoders* possuem um grande potencial de remoção de ruído e tratamento de imagens. Nesse estudo, foram utilizadas para detectar discontinuidades no interior de componentes sem que houvesse qualquer dano a estes e, apesar da qualidade reduzida das imagens, é possível visualizar os defeitos sem dificuldades.

No entanto, seria interessante, em próximos estudos, que houvesse um maior aprofundamento no estudo da arquitetura da rede neural, de modo que reduza o tempo de execução da tarefa, além de diminuir a quantidade de dados usados para aprendizado dos atributos das imagens e melhorar a qualidade do *output* do modelo.

REFERÊNCIAS BIBLIOGRÁFICAS

- BANK, D., KOENIGSTEIN, N., & GIRYES, R. (2020). Autoencoders. <http://arxiv.org/abs/2003.05991>
- CHOI, R. Y., COVNER, A. S., KALPATHY-CRAMER, J., CHIANG, M. F., & PETER CAMPBELL, J. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational Vision Science and Technology*, 9(2). <https://doi.org/10.1167/tvst.9.2.14>
- FERNANDES, H. (2015). Fiber orientation analysis of carbon fiber-reinforced polymers by infrared thermography.
- FERNANDES, H. et al. (2016). Carbon fiber composite inspection and defect characterization using active infrared thermography: numerical simulations and experimental results.
- FRANÇOIS-LAVET, V., HENDERSON, P., ISLAM, R., BELLEMARE, M. G., & PINEAU, J. (2018). An introduction to deep reinforcement learning. *Foundations and Trends in Machine Learning*, 11(3–4), 219–354. <https://doi.org/10.1561/22000000071>
- HRISKO, J. Infrared Thermometry Theory and Applications with Arduino and Python. Maker Portal. <https://makersportal.com/blog/2019/8/8/non-contact-infrared-thermometry-theory-and-applications-with-arduino> (2019).
- HAYKIN, S., (2001), *Neural Networks-A Comprehensive Foundation*.
- KHAKSARI, Kosar et al. Review of the efficacy of infrared thermography for screening infectious diseases with applications to COVID-19. *Journal of Medical Imaging*, v. 8, n. S1, p. 010901-010901, 2021.
- KUMAR, A., SODHI, S. S. "Comparative Analysis of Gaussian Filter, Median Filter and Denoise Autoencoder," 2020 7th International Conference on Computing for Sustainable Global Development (INDIACom), New Delhi, India, 2020, pp. 45-51, doi: 10.23919/INDIACom49435.2020.9083712.
- LECUN, Y., BENGIO, Y. & HINTON, G. Deep learning. *Nature* 521, 436–444 (2015). <https://doi.org/10.1038/nature14539>
- MALDAGUE, X. P. V. "Theory and Practice of Infrared Technology for Nondestructive Testing." (2001).
- PASCAL, V., LAROCHELLE, H., LAJOIE, I., BENGIO, Y., & MANZAGOL, P. A. (2010). Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion In *Journal of Machine Learning Research* (Vol. 11).
- QU, Z., JIANG, P., & ZHANG, W. (2020). Development and application of infrared thermography non-destructive testing techniques. In *Sensors (Switzerland)* (Vol. 20, Issue 14, pp. 1–27). MDPI AG. <https://doi.org/10.3390/s20143851>
- VOLLMER, M., MÖLLMANN, K.-P. (2017). Fundamentals of Infrared Thermal Imaging. In *Infrared Thermal Imaging* (eds M. Vollmer and K.-P. Möllmann).

ZHANG, A., LIPTON, Z., LI, M., & SMOLA, A. (2021). Dive into Deep Learning.