

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
DE SANTA CATARINA
CAMPUS SÃO JOSÉ

JÉSSICA GOMES CARRICO

**DETECÇÃO DE NÓDULOS EM IMAGENS MAMOGRAFICAS
UTILIZANDO APRENDIZADO PROFUNDO E TRANSFORMADA
*WAVELET***

SÃO JOSÉ

2025

Jéssica Gomes Carrico

Detecção de nódulos em imagens mamograficas utilizando aprendizado profundo e transformada *Wavelet*

Projeto de Trabalho de conclusão de curso apresentado à Coordenadoria do Curso de Engenharia de Telecomunicações do Câmpus São José do Instituto Federal de Santa Catarina.

Orientador: Prof. Ramon Mayor Martins,
Dr.

Coorientadora: Profa. Elen Macedo Lobato,
Dra.

São José

2025

RESUMO

O câncer de mama segue sendo uma das principais causas de mortalidade entre mulheres no mundo, sendo a detecção precoce fundamental para aumentar as chances de tratamento eficaz. Neste contexto, o trabalho propõe o desenvolvimento de um sistema de detecção automatizada de nódulos mamários em mamografias, integrando técnicas de pré-processamento com Transformada *Wavelet* e redes neurais convolucionais (CNNs) utilizando aprendizado por transferência (*Transfer Learning*). As imagens utilizadas provêm de bases públicas como *Mini-MIAS*. O desempenho do modelo será avaliado com e sem a aplicação da *Wavelet*, por meio de métricas como acurácia, sensibilidade e especificidade. Espera-se que o uso da *Wavelet* contribua para a melhora na precisão diagnóstica além de demonstrar a viabilidade de soluções baseadas em código aberto na área médica.

Palavras-chave: Câncer de mama. Redes neurais convolucionais. Transformada *Wavelet*. Diagnóstico por imagem. Inteligência artificial

LISTA DE ILUSTRAÇÕES

Figura 1 – Mamografia digital demonstrando nódulo espiculado avaliado com recursos de pós-processamento	8
Figura 2 – Representação anatômica e radiológica da mama	9
Figura 3 – Classificação das densidades mamárias (A a D) segundo o sistema BI-RADS	10
Figura 4 – Sinal no domínio do tempo com mudança de frequência	11
Figura 5 – Transformada Rápida de <i>Fourier</i> do sinal: ausência de localização temporal	12
Figura 6 – Espectrograma da Transformada <i>Wavelet</i> Contínua: análise tempo-frequência	12
Figura 7 – Funções <i>wavelets</i> comuns	13
Figura 8 – Representação em diagrama de blocos da FWT	16
Figura 9 – Arquitetura de uma Rede Neural Convolutiva	18
Figura 10 – Modelo matemático de um neurônio	18
Figura 11 – Fronteira de separação do neurônio de entrada	19
Figura 12 – Topologias de Rede Neural	19
Figura 13 – Rede neural profunda	20
Figura 14 – Exemplo de convolução 2D	21
Figura 15 – Exemplo de <i>pooling</i>	21
Figura 16 – Etapas do processo de Aprendizado de Máquina Centrado no Ser Humano (HCML)	24

SUMÁRIO

1	INTRODUÇÃO	5
1.1	OBJETIVOS GERAIS	6
1.2	OBJETIVOS ESPECÍFICOS	6
2	FUNDAMENTAÇÃO TEÓRICA	7
2.1	CÂNCER DE MAMA	7
2.2	MAMOGRAFIA DIGITAL	7
2.2.1	Mama	8
2.3	PROCESSAMENTO DE IMAGEM	10
2.3.1	Transformada <i>Wavelet</i>	11
2.4	REDES NEURAIS CONVOLUCIONAIS	17
2.4.1	Neurônios (<i>Perceptrons</i>)	18
2.4.2	Rede Neural	19
2.4.3	Convolução	20
2.4.4	<i>Pooling</i> (Subamostragem)	21
2.4.5	Camada Totalmente Conectada	22
2.4.6	<i>Transfer Learning</i> (Aprendizado por transferência)	22
3	REVISÃO DA LITERATURA	23
4	PROPOSTA	24
4.1	TRABALHOS REALIZADOS	24
4.2	METODOLOGIA	25
4.2.1	Coleta de Dados	25
4.2.2	Experimento	26
4.2.3	Implementação	26
4.3	RESULTADOS ESPERADOS	26
4.4	CRONOGRAMA	27
	Referências	28

1 INTRODUÇÃO

O câncer de mama permanece como a principal causa de mortalidade por câncer entre mulheres em todo o mundo, sendo responsável por um grande número de óbitos em diversos países (CADRIN-CHÊNEVERT, 2023; SECHOPOULOS; TEUWEN; MANN, 2021). Apesar dos avanços em métodos de triagem e tratamento, a detecção precoce ainda enfrenta desafios consideráveis, como a variabilidade na interpretação dos exames por profissionais de saúde e a ocorrência de falsos positivos, que podem gerar ansiedade e procedimentos desnecessários para as pacientes.

Nesse cenário, a inteligência artificial (IA) tem se mostrado uma ferramenta promissora no apoio ao diagnóstico do câncer de mama. A utilização de redes neurais convolucionais (CNN), por exemplo, para a detecção de anomalias de forma automática, juntamente com uma avaliação médica, contribui para evitar procedimentos desnecessários, minimizar o impacto psicológico nas pacientes e otimizar os recursos do sistema de saúde (SECHOPOULOS; TEUWEN; MANN, 2021; CADRIN-CHÊNEVERT, 2023).

Para que seja possível utilizar redes neurais na detecção de anormalidades em um exame de mama, é necessário treiná-las previamente. Esse processo envolve fornecer uma grande quantidade de imagens já classificadas, permitindo que a rede aprenda a reconhecer padrões específicos associados. O intuito é de que após esse treinamento, a rede seja capaz de analisar uma nova imagem e fazer uma previsão com base no conhecimento adquirido. Entretanto, treinar redes neurais do zero exige muitos dados rotulados e alto poder computacional. Para contornar essas limitações, utiliza-se o *Transfer Learning*, que reaproveita redes já treinadas em grandes bases, permitindo bons resultados mesmo com menos dados e infraestrutura reduzida (ISIN; OZDALILI, 2017).

Além disso, as imagens precisam passar por um pré-processamento. Essa etapa é necessária para que as imagens “conversem” com o computador, ou seja, estejam em um formato e qualidade que facilite a extração de informações relevantes pelos algoritmos. Uma das técnicas utilizadas nesse processo é a Transformada *Wavelet*, que permite decompor a imagem em níveis de resoluções diferentes (LEITE; HENRIQUES; CUNHA, 2018). Isso facilita a identificação de detalhes sutis, como microcalcificações e bordas de nódulos, ao mesmo tempo em que reduz ruídos indesejados. Dessa forma, o uso da *Wavelet* contribui para tornar os dados mais adequados ao aprendizado da rede neural, aumentando a eficiência na detecção de padrões associados ao câncer de mama.

Diante desse cenário, este trabalho tem como objetivo treinar uma rede neural convolucional com *Transfer Learning* para a detecção de anomalias em imagens de mamografia utilizando uma base de dados pública (ex. *Mini-MIAS*), comparando seu desempenho

com e sem a aplicação da Transformada *Wavelet* como técnica de pré-processamento. A proposta é avaliar se a utilização da *Wavelet* contribui para melhorar a acurácia do modelo, facilitando a identificação de padrões relevantes e auxiliando na detecção precoce do câncer de mama.

1.1 OBJETIVOS GERAIS

Desenvolver um algoritmo para detecção automatizada de nódulos mamários em mamografias, integrando decomposição *Wavelet* multinível e redes neurais convolucionais. Visando aumentar a precisão diagnóstica inclusive em tecidos densos (BI-RADS 3-4).

1.2 OBJETIVOS ESPECÍFICOS

- Selecionar e pré-processar imagens de mamografia provenientes de bases públicas (ex.: *MIAS*).
- Implementar um algoritmo de decomposição *Wavelet* para destacar padrões relevantes nas imagens e remover ruídos.
- Treinar redes neurais convolucionais (CNNs) nas arquiteturas *ResNet-18*, *ResNet-34* e *ResNet-50* com o uso de *Transfer Learning*.
- Avaliar o desempenho do modelo em dois cenários de entrada (com ou sem *Wavelet*), utilizando métricas como acurácia, sensibilidade e especificidade.
- Comparar os resultados obtidos para verificar o impacto das técnicas de pré-processamento na detecção automatizada de nódulos mamários.

2 FUNDAMENTAÇÃO TEÓRICA

A proposta deste trabalho, é realizar a detecção de nódulos mamários em mamografias por meio de uma rede neural convolucional. Nesse processo, as imagens passam inicialmente por uma etapa de pré-processamento com a Transformada *Wavelet*, aplicada para remoção de ruído (*denoising*), antes de serem processadas pela CNN. Assim, nessa seção é explanado os principais tópicos para alcançar os objetivos pretendidos.

2.1 CÂNCER DE MAMA

O câncer de mama pode se desenvolver a partir de alterações nas células dos lóbulos e ductos mamários. Inicialmente, essas alterações podem incluir um crescimento exagerado de células (hiperplasia) ou um padrão anormal de crescimento (hiperplasia atípica). Com o tempo, podem evoluir para uma forma localizada da doença, que ainda não se espalhou para os tecidos vizinhos (carcinoma in situ), e depois para uma forma mais agressiva, que invade os tecidos ao redor (carcinoma invasivo). Um dos sinais visíveis da doença é a pele da mama ficar parecida com uma casca de laranja, por causa do inchaço. Além disso, também é comum sentir caroços (linfonodos aumentados) na axila (BRAVO et al., 2021).

Trata-se da principal causa de mortalidade por câncer entre mulheres em todo o mundo, com sua incidência influenciada por fatores genéticos, hormonais e de estilo de vida. A detecção precoce da doença é fundamental para aumentar as chances de cura e reduzir a mortalidade, sendo geralmente realizada por meio de exames de imagem, como a mamografia, que permite identificar alterações suspeitas ainda em estágios iniciais (CADRIN-CHÊNEVERT, 2023; SECHOPOULOS; TEUWEN; MANN, 2021).

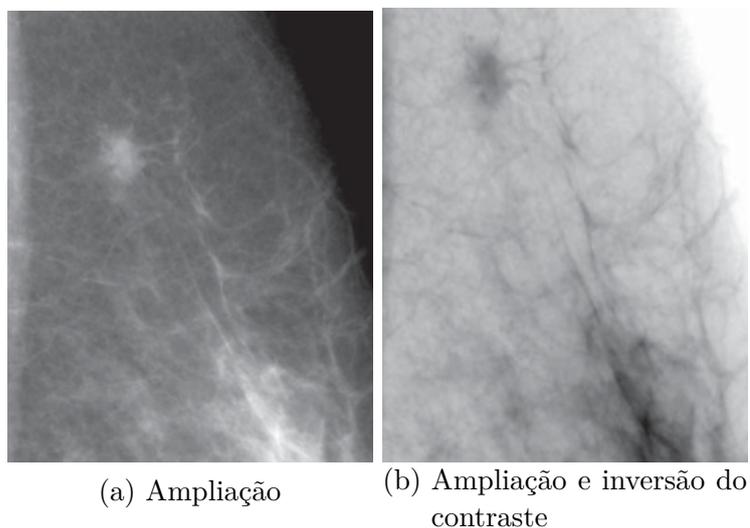
Entre os elementos observados nas mamografias, destacam-se o tamanho do tumor e o envolvimento dos gânglios axilares, fatores que auxiliam na definição da conduta clínica, como a necessidade de quimioterapia ou cirurgia de retirada (BRAVO et al., 2021). Além disso, a forma e o contorno dos nódulos também são considerados: nódulos com formato oval, bordas bem definidas e aspecto regular tendem a ser benignos, enquanto alterações irregulares podem indicar malignidade (PASSIG E SILVA, 2022)

2.2 MAMOGRAFIA DIGITAL

A mamografia digital é uma técnica avançada de diagnóstico por imagem utilizada para detectar alterações no tecido mamário, com ênfase na identificação precoce do câncer de mama. Diferente da mamografia convencional, que utiliza filmes radiográficos, a versão digital emprega detectores eletrônicos para capturar a radiação transmitida pela mama,

convertendo-a em sinais digitais. Esses sinais são processados por algoritmos computacionais, permitindo ajustes precisos de brilho, contraste e ampliação da imagem (Figura 1), sem a necessidade de nova exposição à radiação (FREITAS et al., 2006).

Figura 1 – Mamografia digital demonstrando nódulo espiculado avaliado com recursos de pós-processamento

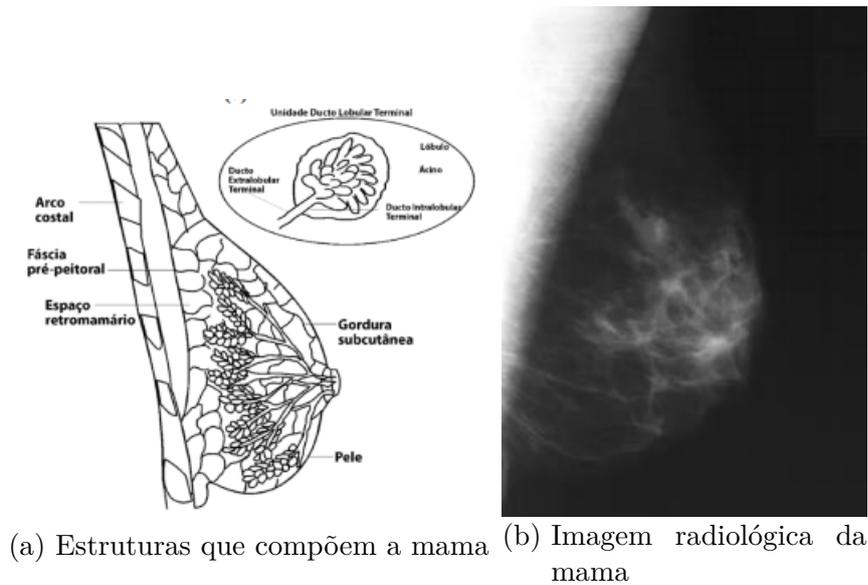


Fonte: (FREITAS et al., 2006).

2.2.1 Mama

A mama é formada por diferentes tipos de tecido, como o tecido gorduroso (adioso), o tecido fibroglandular e os ductos que transportam o leite. Nas imagens de mamografia, o tecido gorduroso aparece mais claro, enquanto o tecido fibroglandular aparece mais escuro (observa-se em Figura 2), o que ajuda a identificar diferentes áreas da mama. A quantidade desses tecidos varia de mulher para mulher, o que pode influenciar na visualização das imagens e na detecção de possíveis alterações (SOUSA, 2017).

Figura 2 – Representação anatômica e radiológica da mama



Fonte: (SOUSA, 2017).

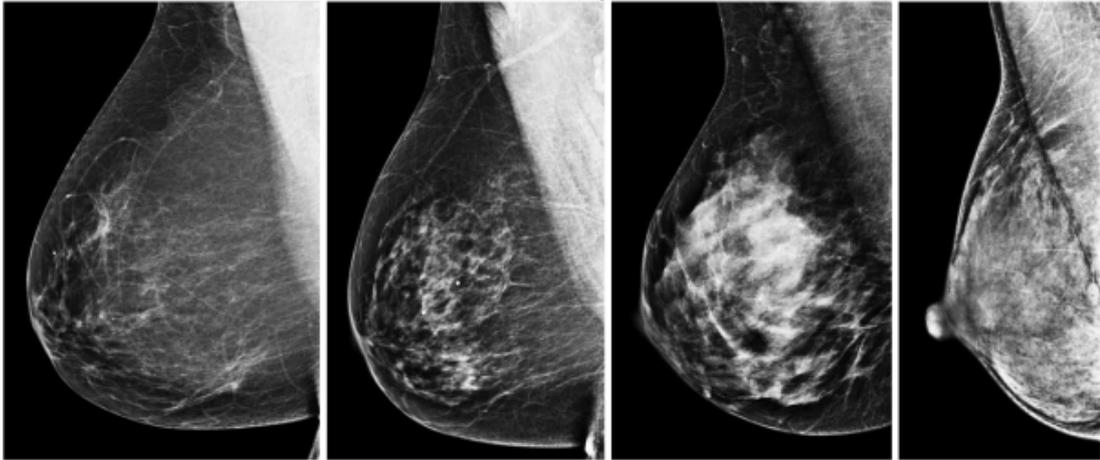
Devido à variação de densidade mamária entre as pacientes, o sistema BI-RADS (*Breast Imaging Reporting and Data System*) propôs uma classificação padronizada que descreve o grau de densidade observado nas imagens mamográficas. Essa categorização auxilia radiologistas na avaliação da qualidade da imagem e na estimativa da possibilidade de lesões não serem visualizadas, contribuindo diretamente para a conduta clínica e o acompanhamento da paciente.

O BI-RADS classifica a densidade mamária em quatro categorias:

- **A:** mama composta quase inteiramente por gordura;
- **B:** presença de áreas dispersas de tecido fibroglandular;
- **C:** mama heterogeneamente densa, podendo ocultar pequenas lesões;
- **D:** mama extremamente densa, com maior risco de mascaramento de alterações.

Na Figura 3, observa-se que mamas com maior proporção de tecido gorduroso tendem a facilitar a identificação de nódulos, uma vez que o contraste entre estruturas é mais evidente. Por outro lado, em mamas densas, a sobreposição de tecidos pode dificultar a detecção de alterações sutis, o que representa um desafio diagnóstico em exames mamográficos (SOUSA, 2017).

Figura 3 – Classificação das densidades mamárias (A a D) segundo o sistema BI-RADS



Fonte: (SOUSA, 2017).

2.3 PROCESSAMENTO DE IMAGEM

Para o tratamento de imagens mamográficas utiliza-se técnicas de processamento de imagem. Uma técnica utilizada em processamento de imagens é a limiarização. Ela consiste em aplicar um valor limite (limiar) para separar os pixels importantes do fundo em uma imagem. Pixels com intensidade igual ou superior ao limiar recebem valor 1, e os demais, 0, gerando uma imagem binária. Multiplicando essa imagem binária pelos valores originais, mantém-se apenas os pixels relevantes, eliminando o fundo (PASSIG E SILVA, 2022). A seguir, apresenta-se um exemplo prático de limiarização:

$$I = \begin{bmatrix} 10 & 50 & 200 \\ 30 & 100 & 180 \\ 20 & 40 & 220 \end{bmatrix}, \quad T = 100 \quad (2.1)$$

$$B(x, y) = \begin{bmatrix} 0 & 0 & 1 \\ 0 & 1 & 1 \\ 0 & 0 & 1 \end{bmatrix}, \quad B(x, y) = \begin{cases} 1, & I(x, y) \geq T \\ 0, & \text{caso contrário} \end{cases} \quad (2.2)$$

$$I'(x, y) = I(x, y) \times B(x, y) = \begin{bmatrix} 0 & 0 & 200 \\ 0 & 100 & 180 \\ 0 & 0 & 220 \end{bmatrix} \quad (2.3)$$

onde I é a matriz da imagem original contendo os valores de intensidade dos pixels, T é o limiar definido para separar o fundo dos objetos de interesse, B é a imagem binária resultante da aplicação do limiar, e I' é a imagem final obtida após a multiplicação elemento a elemento, que mantém apenas os pixels com intensidade igual ou superior a T .

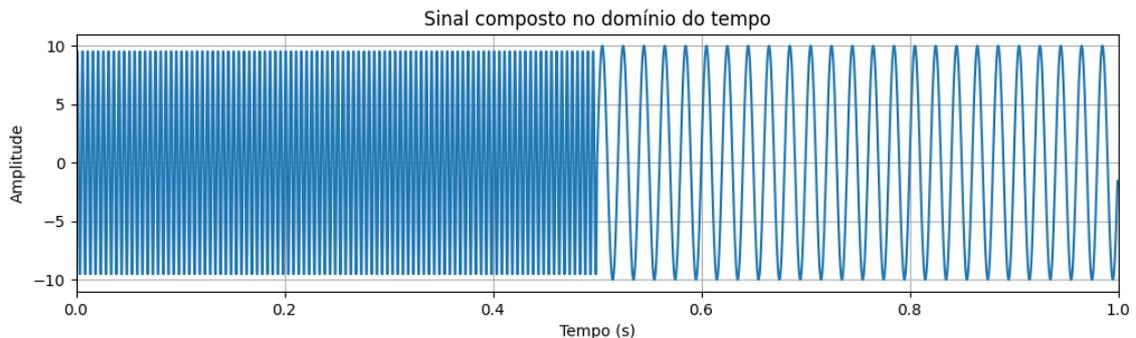
Embora uma imagem não tenha variação temporal (como um sinal de áudio, por exemplo), ela possui variações espaciais na intensidade dos pixels que podem ser interpretadas em termos de frequência. Áreas com transições suaves correspondem a baixas frequências, enquanto detalhes, bordas ou texturas correspondem a altas frequências. Por isso, técnicas como a Transformada Wavelet (subseção 2.3.1) podem ser aplicadas a imagens para decompor essas variações em diferentes escalas, permitindo destacar padrões importantes e reduzir ruídos, o que facilita a extração de informações relevantes para etapas posteriores de processamento.

2.3.1 Transformada *Wavelet*

A Transformada *Wavelet* surge como uma solução para uma limitação da Transformada de Fourier. Ambas têm como objetivo transformar um sinal do domínio do tempo para o domínio da frequência. No entanto, a Transformada de *Fourier* não permite identificar em que momento uma determinada frequência ocorre, fazendo com que a sua aplicação torne-se limitada na análise de sinais com variações ao longo do tempo (não estacionários) (DOMINGUES et al., 2016).

A Figura 4 ilustra um sinal no domínio do tempo, composto por uma frequência de 200 Hz no intervalo entre 0 e 0.5 segundos, e por uma frequência de 50 Hz a partir de 0.5 segundos.

Figura 4 – Sinal no domínio do tempo com mudança de frequência

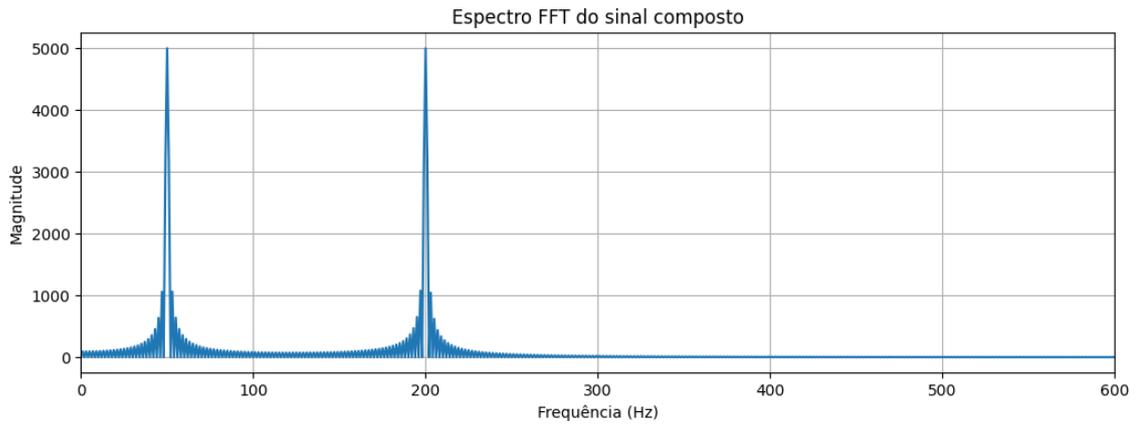


Fonte: Elaborada pela autora.

Ao aplicar a Transformada Rápida de *Fourier* ao sinal, obtém-se a representação no domínio da frequência (Figura 5). Embora ela revele as frequências presentes, não indica em que momento essas frequências ocorrem no sinal.

Para contornar essa limitação e extrair informações simultaneamente no tempo e na frequência, é necessário adotar uma abordagem diferente, como o janelamento do sinal (DOMINGUES et al., 2016), o que leva ao uso da Transformada *Wavelet*. Embora sua fundamentação seja semelhante à da Transformada Rápida de *Fourier* (FFT), a Transformada *Wavelet* difere ao decompor o sinal não em senóides, mas em funções *wavelets*

Figura 5 – Transformada Rápida de *Fourier* do sinal: ausência de localização temporal

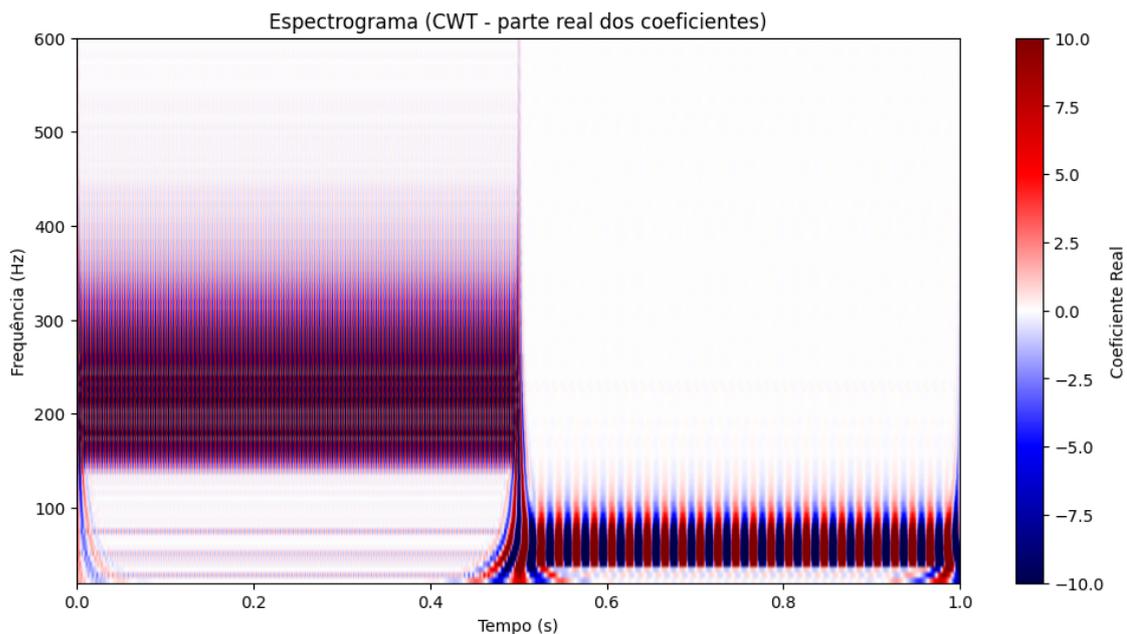


Fonte: Elaborada pela autora.

(ondas de curta duração que se atenuam rapidamente). Isso permite capturar eventos transitórios e mudanças abruptas com maior precisão. As *wavelets* são funções localizadas tanto no tempo, por meio de translações, quanto na frequência ou escala, por meio de dilatações, possibilitando uma análise mais refinada de sinais não estacionários.

A Figura 6 mostra o espectrograma gerado pela aplicação da Transformada *Wavelet* Contínua (CWT, do inglês *Continuous Wavelet Transform*) ao sinal. É possível observar não apenas as frequências presentes, mas também os momentos em que elas ocorrem, evidenciando a vantagem da análise conjunta no tempo e na frequência.

Figura 6 – Espectrograma da Transformada *Wavelet* Contínua: análise tempo-frequência



Fonte: Elaborada pela autora.

A Transformada *Wavelet* Contínua de uma função $x(t) \in L^2(\mathbb{R})$ pode ser definida

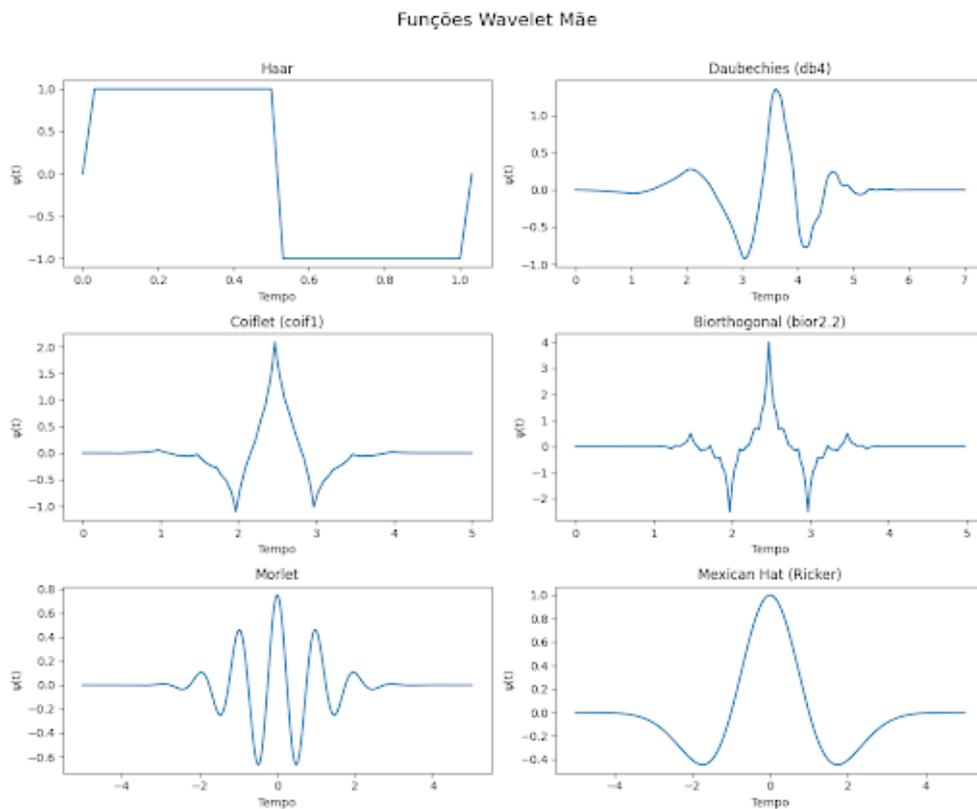
conforme a Equação 2.4. Nessa expressão, o parâmetro a representa o *fator de dilatação* (ou escala), b é o *deslocamento temporal* (ou translação), e ψ é a *wavelet mãe* (GOSWAMI; CHAN, 1999).

$$W_{\psi,x}(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt \quad (2.4)$$

Wavelets mães

Na Transformada *Wavelet*, as funções *wavelets* são obtidas a partir de uma função geradora, sendo denominada como *wavelet* mãe. As *Wavelets* mães são sinais que ao serem deslocados, multiplicados, ou outras transformações, formam uma família (PASSIG E SILVA, 2022). Dentre as famílias de *wavelets* mais conhecidas estão a *Coiffet*, *Daubechies*, *Haar*, *Biorthogonal* e *Morlet* e *Mexican Hat* (Chapéu Mexicano), que são ilustradas na Figura 7

Figura 7 – Funções *wavelets* comuns



Fonte: Elaborada pela autora.

Tem-se que a *wavelet* mãe apresentada na Equação 2.4 deve satisfazer duas condições essenciais (MAGRINI, 2020):

- Ter valor médio nulo (Equação 2.5);

- Possuir energia finita (Equação 2.6).

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (2.5)$$

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad (2.6)$$

Transformada Wavelet Discreta

A Transformada *Wavelet* Discreta (DWT, do inglês *Discrete Wavelet Transform*) é construída a partir da discretização dos parâmetros de escala e translação utilizados na Transformada *Wavelet* Contínua (CWT). Essa discretização permite reescrever a integral da CWT como uma soma discreta (GOSWAMI; CHAN, 1999), viabilizando sua implementação computacional por meio de algoritmos baseados em bancos de filtros (tema abordado posteriormente no tópico seção 2.3.1).

Na DWT, o sinal é decomposto em níveis de resolução, o que permite analisar separadamente as componentes de baixa frequência (aproximação) e as componentes de alta frequência (detalhe).

Parâmetros de escala e translação

O parâmetro $j \in \mathbb{Z}$ representa o *nível de escala*. Quanto maior o valor de j , mais dilatada é a *wavelet* no tempo, permitindo capturar tendências globais (baixas frequências) do sinal. Já valores menores de j correspondem a *wavelets* mais comprimidas, úteis para detectar variações rápidas (altas frequências).

O parâmetro $k \in \mathbb{Z}$ determina a *posição temporal* da análise, indicando onde a *wavelet* é aplicada ao sinal. Ao variar k , é possível “varrer” o sinal ao longo do tempo e detectar eventos locais.

Representação do sinal com funções base

A partir da discretização dos parâmetros de escala e translação, o sinal $f[n]$ pode ser representado como uma combinação de funções base (PASSIG E SILVA, 2022):

- As *funções escalares* $\phi_{j,k}[n]$, associadas às aproximações (componentes de baixa frequência);
- As *funções wavelet mãe* $\psi_{j,k}[n]$, associadas aos detalhes (componentes de alta frequência).

A decomposição multirresolução do sinal é expressa por:

$$f[n] = \sum_{k=-\infty}^{\infty} c_{j,k} \phi_{j,k}[n] + \sum_{j=0}^{\infty} \sum_{k=-\infty}^{\infty} d_{j,k} \psi_{j,k}[n] \quad (2.7)$$

Onde:

- $c_{j,k}$: coeficientes de aproximação no nível mais baixo (mais grosseiro);
- $d_{j,k}$: coeficientes de detalhe para cada nível j ;
- J : nível inicial da decomposição (resolução mais baixa).

Cálculo de $\phi_{j,k}[n]$ e $\psi_{j,k}[n]$

As funções $\phi_{j,k}[n]$ e $\psi_{j,k}[n]$ são versões escaladas e transladadas das funções $\phi[n]$ (função escalar) e $\psi[n]$ (função *wavelet* mãe) (PASSIG E SILVA, 2022), definidas da seguinte forma:

$$\phi_{j,k}[n] = a_0^{-j/2} \cdot \phi\left(\frac{n - kb_0a_0^j}{a_0^j}\right) \quad (2.8)$$

$$\psi_{j,k}[n] = a_0^{-j/2} \cdot \psi\left(\frac{n - kb_0a_0^j}{a_0^j}\right) \quad (2.9)$$

onde fator $a_0^{-j/2}$ garante a normalização da energia das funções em diferentes escalas (GOSWAMI; CHAN, 1999). O termo $a_0^j n$ realiza a dilatação (controlando a frequência), sendo o equivalente ao a da CWT, enquanto $kb_0a_0^j$ define a translação no tempo (controlando a posição da análise), equivalente ao b da CWT. Deste modo, a DWT é formalmente definida como:

$$\begin{aligned} W_f(j, k) &= \sum_{n=-\infty}^{\infty} f[n] \cdot \psi_{j,k}[n] \\ &= \sum_{n=-\infty}^{\infty} f[n] \cdot a_0^{-j/2} \psi\left(\frac{n - kb_0a_0^j}{a_0^j}\right) \quad ; \quad a_0 > 1; b_0 \neq 0. \end{aligned} \quad (2.10)$$

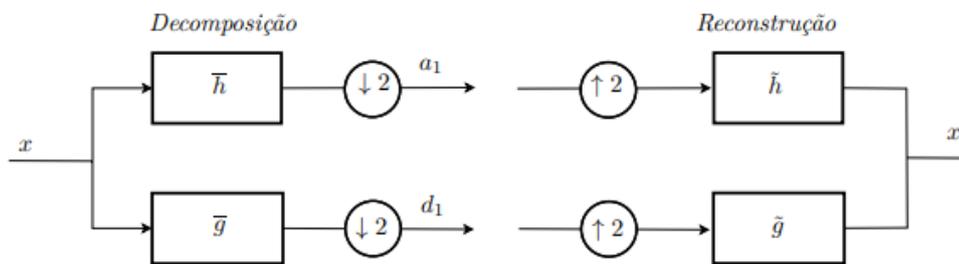
Banco de filtros

A Transformada *Wavelet* Discreta pode ser implementada de maneira eficiente por meio de um banco de filtros digital, estrutura conhecida como *Fast Wavelet Transform* (FWT). Esse método evita a construção explícita das funções $\phi_{j,k}[n]$ e $\psi_{j,k}[n]$, ao calcular diretamente os coeficientes de aproximação e de detalhe a partir de operações de filtragem e subamostragem.

O procedimento consiste em aplicar dois filtros ao sinal: um filtro passa-baixa (\bar{h}), que preserva as componentes de baixa frequência, e um filtro passa-alta (\bar{g}), que isola as componentes de alta frequência. Após a filtragem, realiza-se a subamostragem (redução pela metade da taxa de amostragem), o que resulta nos coeficientes de aproximação e de detalhe para aquele nível de análise (MAGRINI, 2020).

Esse processo pode ser repetido recursivamente sobre os coeficientes de aproximação, permitindo a decomposição do sinal em múltiplos níveis de resolução. A estrutura do banco de filtros, composta pelas etapas de decomposição e reconstrução, é ilustrada na Figura 8.

Figura 8 – Representação em diagrama de blocos da FWT



Fonte: (MAGRINI, 2020).

Essa abordagem é amplamente utilizada em aplicações reais, como compressão de sinais, análise de transientes e remoção de ruído, por ser computacionalmente eficiente.

Wavelet denoising

O processo de remoção de ruídos utilizando a Transformada *Wavelet* consiste basicamente em três etapas principais, conforme apresentado no TCC de Passig e Silva (2022):

1. **Decomposição:** O sinal original x é decomposto em coeficientes *wavelet* C através da transformada wavelet, conforme a Equação (2.11):

$$C = W(x) \quad (2.11)$$

2. **Limiarização:** Aplica-se um operador $D(C, \alpha)$, que realiza a remoção do ruído por meio da limiarização dos coeficientes, onde α é o limiar definido para distinguir ruído de sinal significativo, conforme a Equação (2.12):

$$C_d = D(C, \alpha) \quad (2.12)$$

Segundo Mupparaju e Jahnavi (2013), podemos definir o limiar universal (ou VisuShrink) α como:

$$\alpha = \sigma \sqrt{2 \log I} \quad (2.13)$$

onde σ é a variância do ruído e I é o número total de pixels da imagem. Apesar de simples, esse método tende a produzir uma estimativa excessivamente suavizada quando I é grande.

Além disso, a limiarização pode ser aplicada de duas formas:

- ***Hard thresholding* (Limiar rígido):**

$$T_{hard}(d, \lambda) = d \cdot \mathbf{1}(|d| > \lambda) \quad (2.14)$$

- ***Soft thresholding* (Limiar suave):**

$$T_{soft}(d, \lambda) = \text{sign}(d) \cdot (|d| - \lambda)_+ \quad (2.15)$$

onde d representa o coeficiente do sinal e λ o limiar aplicado.

3. **Reconstrução:** Por fim, a transformada *wavelet* inversa é aplicada aos coeficientes limiarizados para obter o sinal *denoised* $s(t)$, conforme a Equação (2.16):

$$s(t) = W^{-1}(C_d) \quad (2.16)$$

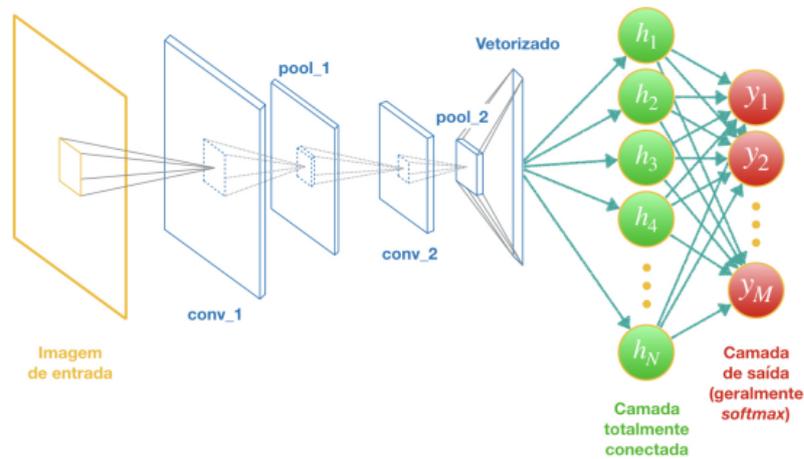
O nível de decomposição, ou seja, a quantidade de vezes que o sinal é subdividido em componentes de alta e baixa frequência, também influencia o resultado do *denoising*, podendo afetar a preservação do sinal original.

2.4 REDES NEURAS CONVOLUCIONAIS

As Redes Neurais Convolucionais (CNNs, do inglês *Convolutional Neural Networks*) constituem uma arquitetura específica de redes neurais profunda que incorpora a operação matemática de convolução em pelo menos uma de suas camadas (ROSA, 2025). Essa abordagem favorece a extração eficiente de padrões espaciais e estruturais dos dados de entrada (MIYAZAKI, 2017). Ao abordar imagens como objetos de entrada, (que podem ser compreendidas como uma grade bidimensional de pixels) as CNNs se demonstram adequadas (CUNHA, 2020).

De forma geral, a arquitetura de uma CNN segue um fluxo bem definido: os dados de entrada (como uma imagem) passam por camadas convolucionais, que extraem características locais; em seguida, por camadas de *pooling*, que reduzem a dimensionalidade; depois, por camadas totalmente conectadas (*fully connected*), responsáveis pela tomada de decisão com base nas características extraídas; até, finalmente, gerar a saída (MIYAZAKI, 2017). A Figura 9 ilustra esse processo de forma simplificada.

Figura 9 – Arquitetura de uma Rede Neural Convolucional

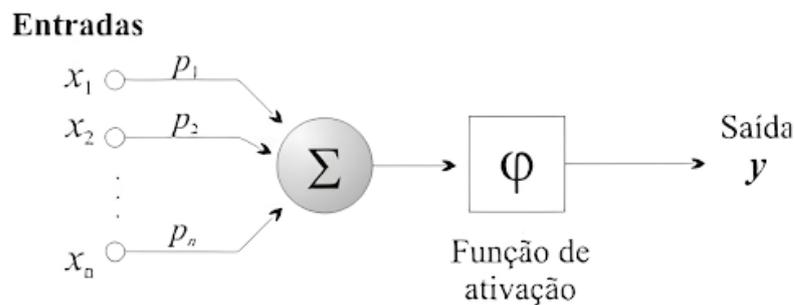


Fonte: (SILVA JUNIOR, 2022).

2.4.1 Neurônios (*Perceptrons*)

Para compreendermos o funcionamento das redes neurais profunda, é essencial entender primeiro o que faz um único neurônio (perceptrons). Sua função é receber uma ou mais entradas, calcular uma combinação linear ponderada dessas entradas com base em pesos associados e, em seguida, aplicar uma função de ativação para gerar uma saída, conforme mostra a Figura 10. Geometricamente, esse processo define um hiperplano no espaço das entradas, que serve para separar os dados conforme suas classes ou características.

Figura 10 – Modelo matemático de um neurônio



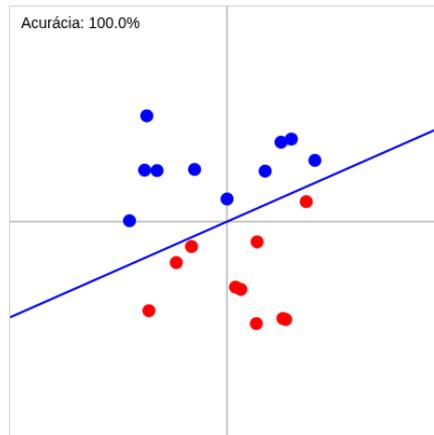
Fonte: (FERNEDA, 2006).

Na Figura 11, os pesos atribuídos são $w_1 = -0,40$, $w_2 = 0,90$, e o *bias* é $b = 0,00$. A equação resultante do hiperplano é:

$$-0,40x + 0,90y + 0,00 = 0$$

Os pontos azuis representam a classe positiva, enquanto os vermelhos indicam a classe negativa. Essa visualização ilustra como os pesos e o bias afetam diretamente a fronteira de decisão.

Figura 11 – Fronteira de separação do neurônio de entrada



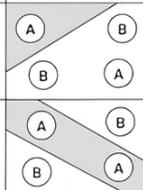
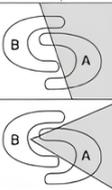
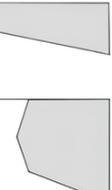
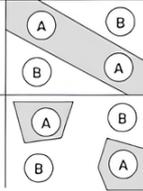
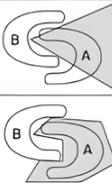
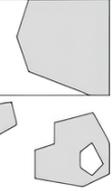
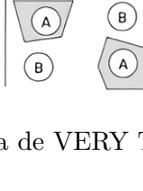
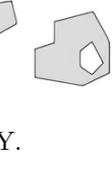
Fonte: (MARTINS, 2025).

Em redes neurais com múltiplos neurônios, cada um define seu próprio hiperplano. A combinação desses hiperplanos permite que a rede realize decisões mais complexas, separando dados de maneira mais precisa mesmo em casos em que as classes não são linearmente separáveis.

2.4.2 Rede Neural

Chamamos de rede neural quando há mais de um neurônio trabalhando em conjunto para realizar decisões. Existem diversas topologias possíveis, como por exemplo: *single-layer* (camada única), *two-layer* (duas camadas), *three-layer* (três camadas), entre outras configurações, dependendo da complexidade da tarefa a ser resolvida, conforme observa-se na Figura 12.

Figura 12 – Topologias de Rede Neural

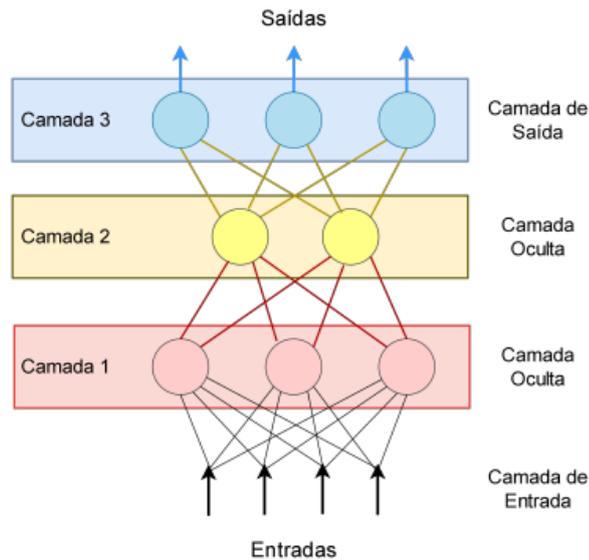
	Tipo de Regiões de Decisão	Problema OU Exclusivo	Classes com Regiões Entrelaçadas	Formas de Regiões Mais Gerais
Camada Única 	Semi-plano Delimitado por Hiperplano			
Duas Camadas 	Regiões Convexas Abertas ou Fechadas			
Multicamadas 	Arbitrárias (Complexidade Limitada pelo Número de Nós)			

Fonte: Adaptada de VERY TECHNOLOGY.

Rede Neural Profunda

Quando se forma uma estrutura em que os neurônios são organizados em múltiplas camadas, tem-se uma rede neural profunda (DNN, do inglês *Deep Neural Network*), como mostrado na Figura 13. Esse tipo de rede permite o processamento hierárquico dos dados, em que cada camada utiliza as saídas da anterior para extrair informações mais complexas.

Figura 13 – Rede neural profunda

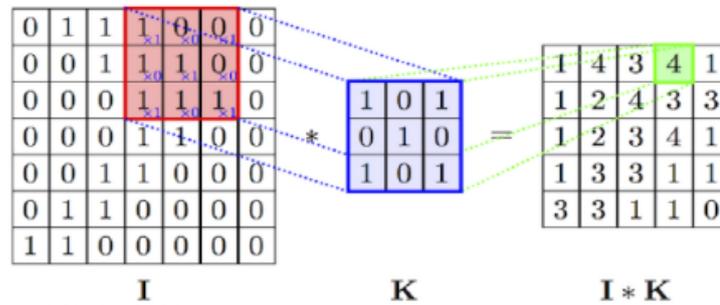


Fonte: (ROSA, 2025).

2.4.3 Convolução

A principal camada de uma Rede Neural Convolutional é a camada de Convolução. No contexto de uma convolução 2D (aplicada a imagens não coloridas), a imagem de entrada é representada como uma matriz de pixels e processada por um pequeno filtro, conhecido como *kernel*. Esse *kernel* é deslocado sobre a imagem, sendo posicionado em regiões sucessivas. Em cada posição, realiza-se a multiplicação elemento a elemento entre os valores do *kernel* e os da região correspondente da imagem, seguida pela soma desses produtos para gerar um único valor. Cada valor obtido compõe um ponto de uma nova matriz chamada mapa de características (*feature map*) (ROSA, 2025). Como ilustrado na Figura 14.

Figura 14 – Exemplo de convolução 2D



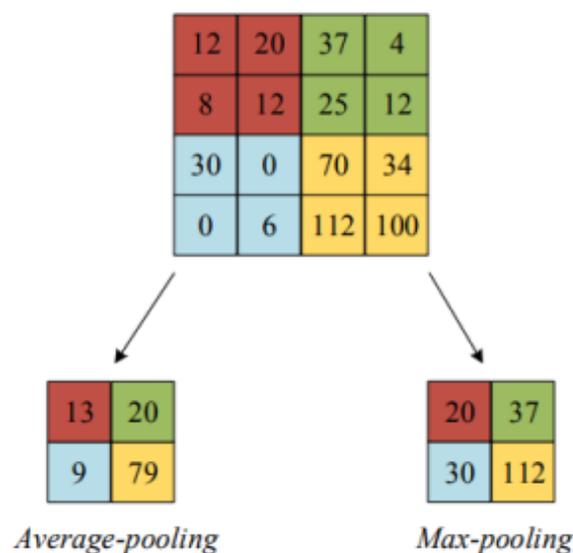
Fonte: (ROSA, 2025).

2.4.4 Pooling (Subamostragem)

Outra camada importante em uma CNN é a camada Pooling. Dois tipos comuns de operações de agrupamento (*pooling*) em redes neurais convolucionais são o *Max Pooling* e o *Average Pooling* (Figura 15). Ambas as técnicas atuam sobre regiões locais da imagem de entrada, definidas por um *kernel* deslizante.

O *Max Pooling* retorna, para cada região coberta pelo *kernel*, o valor máximo entre os elementos daquela vizinhança. Essa abordagem é a mais frequentemente utilizada, pois preserva os recursos mais significativos detectados durante a convolução. Além disso, contribui para a supressão de ruídos, descartando ativações de baixa intensidade.

Já o *Average Pooling*, por outro lado, calcula a média dos valores contidos na região coberta pelo *kernel*. Embora também reduza a dimensionalidade, tende a suavizar a representação da imagem, o que pode levar à perda de informações mais marcantes.

Figura 15 – Exemplo de *pooling*

Fonte: (ROSA, 2025).

2.4.5 Camada Totalmente Conectada

Após passarem por diversas camadas de convolução e pooling, os *feature maps* são progressivamente reduzidos até serem transformados em uma representação unidimensional. Esse vetor resultante é então utilizado como entrada para uma camada totalmente conectada, na qual cada neurônio se conecta a todos os neurônios da camada anterior. Essa etapa permite à rede combinar as características extraídas e identificar padrões de maior complexidade (ROSA, 2025).

2.4.6 *Transfer Learning* (Aprendizado por transferência)

O *Transfer Learning* tem se destacado como uma abordagem eficaz para reduzir o tempo e os recursos computacionais necessários no treinamento de grandes modelos de aprendizado profundo. Essa técnica consiste em reutilizar modelos previamente treinados em grandes bases de dados, para extrair características relevantes mesmo em cenários com poucos dados rotulados (ISIN; OZDALILI, 2017).

A transferência de conhecimento aproveita os vetores de características gerados por redes neurais profundas já treinadas, utilizando seus pesos sinápticos configurados para reconhecer e extrair informações de conjuntos de dados anteriores. Esses vetores servem como descritores das imagens do novo conjunto e podem ser usados para treinar um novo classificador ou inseridos diretamente nas camadas totalmente conectadas da arquitetura original, após ajustes finos (*fine-tuning*) nas camadas convolucionais (AGUIAR NETO, 2017). Assim, essa estratégia tem se mostrado especialmente vantajosa em áreas como a Medicina, onde a disponibilidade de grandes volumes de dados rotulados é limitada.

3 REVISÃO DA LITERATURA

A integração entre redes neurais convolucionais (CNNs) e transformadas *Wavelet* tem demonstrado eficácia significativa na análise de mamografias, especialmente para identificação de lesões sutis como microcalcificações e distorções arquiteturais (BLAHOVÁ; KOSTOLNÝ; CIMRÁK, 2025; OYELADE; EZUGWU, 2022). Essa abordagem extrai características multiescala que amplificam padrões relevantes para o diagnóstico precoce do câncer de mama (OYELADE; EZUGWU, 2022).

Técnicas tradicionais de aumento de dados, como rotação e espelhamento, equilibram classes raras (ex.: distorções arquiteturais), reduzindo falsos positivos em até 12% e melhorando a sensibilidade para microcalcificações em 9,3%. Essa estratégia mitiga desequilíbrios amostrais e aprimora a generalização dos modelos (BLAHOVÁ; KOSTOLNÝ; CIMRÁK, 2025).

Com a base de dados *Mini-MIAS*, a aplicação de *Wavelets Haar* como pré-processamento em arquiteturas *ResNet/VGG* alcançou 98,5% de acurácia na detecção de nódulos malignos, isolando padrões de alta frequência em bordas irregulares (RASHEED et al., 2021). Complementarmente, redes híbridas que combinam *Wavelet* e CNN melhoraram a discriminação de microcalcificações em tecidos densos, atingindo acurácia de 85% com *EfficientNet*, 80,9% com *ResNet101* e 83,4% com *AmoebaNet-C* (BANERJEE; KABIR, 2024).

Com a base de dados *CBIS-DDSM*, modelos *Wavelet-CNN* atingiram 87,2% de acurácia na identificação de distorções arquiteturais e microcalcificações, com sensibilidade de 85,4% (OYELADE; EZUGWU, 2022). Em comparação com abordagens anteriores, a superioridade da integração *Wavelet-CNN* é evidenciada em comparações diretas:

Oyelade e Ezugwu (2022) superaram métodos como CNN-DW (Jadoon et al. (2017): 81,83% de acurácia) e CNN tradicional (Teare et al. (2017): 85–88%), alcançando 87,2% de acurácia e AUC 0,96 no *CBIS-DDSM*.

Embora Bakkour e Afdel (2017) tenham reportado 97,28% de acurácia com aumento de dados, sua abordagem não incorporou transformadas *Wavelet*, limitando a extração de características multiescala (OYELADE; EZUGWU, 2022).

Assim, essa combinação entre CNNs e transformadas wavelet representa uma abordagem consolidada na análise de mamografias, evidenciando ganhos quantificáveis na detecção de lesões sutis e na redução de falsos positivos. Esses avanços estabelecem as bases para a exploração de arquiteturas otimizadas e estratégias de pré-processamento desta pesquisa.

4 PROPOSTA

Este trabalho propõe o desenvolvimento de um modelo de aprendizado profundo para detecção de nódulos mamários, utilizando redes neurais convolucionais com transfer learning e técnicas de pré-processamento por Transformada *Wavelet*. A proposta será implementada a partir de bases públicas de mamografias, com imagens previamente anotadas, e ferramentas de código aberto. O modelo será treinado e avaliado em diferentes cenários, com e sem o uso da *Wavelet*, e os resultados serão analisados por meio de métricas como acurácia, sensibilidade e especificidade, com o objetivo de investigar o impacto do pré-processamento na performance do sistema de detecção.

4.1 TRABALHOS REALIZADOS

O desenvolvimento deste trabalho segue os princípios do processo de Aprendizado de Máquina Centrado no Ser Humano (HCML - *Human-Centered Machine Learning*) proposto por Martins et al. (2023), conforme representado na Figura 16.

Figura 16 – Etapas do processo de Aprendizado de Máquina Centrado no Ser Humano (HCML)



Fonte: (MARTINS et al., 2024).

Esse processo compreende as seguintes etapas: 1-análise dos requisitos, 2-preparação dos dados, 3-treinamento do modelo, 4-avaliação do modelo, 5-predição e 6-exportação. Tais fases não são necessariamente lineares, sendo comum o retorno iterativo entre o treinamento e a avaliação até a obtenção de um modelo satisfatório.

Como fase preliminar desta pesquisa, iniciou-se pela seleção da base de dados. A base de dados selecionada foi a *Mini-MIAS*, fundamentada por meio da revisão narrativa da literatura. Esta base tem ampla adoção em estudos relacionados à detecção de nódulos mamários, o que permite estabelecer comparações com arquiteturas modernas como a *ResNet* (*ResNet-18*, *ResNet-34* e *ResNet-50*). Essa base fornece imagens previamente anotadas e categorizadas, com qualidade suficiente para o desenvolvimento e avaliação de modelos de aprendizado profundo voltados ao diagnóstico por imagem.

Atualmente, o projeto encontra-se na fase de preparação de dados, etapa crítica que envolve o reconhecimento e organização dos dados, para posterior pré-processamento

das imagens mamográficas, incluindo a aplicação da Transformada Wavelet Discreta multinível. Este passo inicial, irá permitir que a transformada Wavelet seja aplicada e possa em próximas etapas realçar padrões relevantes e atenuar ruídos, tornando os dados mais apropriados para o treinamento das redes neurais convolucionais com aprendizado por transferência.

4.2 METODOLOGIA

A metodologia deste trabalho segue uma abordagem estruturada baseada nos princípios do Aprendizado de Máquina Centrado no Ser Humano (HCML — *Human-Centered Machine Learning*), já apresentados na Seção 4.1. Esse processo orienta o desenvolvimento iterativo desde a análise de requisitos até a geração de previsões com o modelo final. Ele fornece um direcionamento claro para cada etapa do experimento, permitindo uma condução sistemática e alinhada com boas práticas de desenvolvimento em aprendizado de máquina.

A pesquisa é de natureza quantitativa, aplicada e classificada como um quase-experimento tecnológico (GIL, 2002), por envolver base em análise estatística, utilizando dados secundários (prontos).

4.2.1 Coleta de Dados

Serão utilizadas imagens provenientes da base pública *Mini-MIAS*, compostas por dados secundários quantitativos, como imagens de mamografia e anotações feitas por radiologistas.

Mini-MIAS

A base *Mini-MIAS* (*Mammographic Image Analysis Society*) é amplamente utilizada em pesquisas sobre detecção de câncer de mama e consiste em um subconjunto da base original MIAS, contendo 322 imagens mamográficas digitalizadas a partir de filmes do programa nacional de triagem do Reino Unido. As imagens possuem resolução de 1024×1024 pixels, em formato PGM (*Portable Gray Map*). Cada imagem é acompanhada de anotações fornecidas por radiologistas, que indicam a presença, o tipo (como massa, calcificação, distorção arquitetural) e a localização aproximada das anomalias por meio de coordenadas do centro e raio de uma elipse. Vale destacar que esses rótulos representam avaliações clínicas, e não confirmação histopatológica, o que deve ser considerado na análise dos resultados. Ainda assim, essa base permite o treinamento e a avaliação de modelos voltados à triagem e apoio ao diagnóstico, especialmente em contextos de investigação de densidade mamária e detecção de nódulos (MAMMOGRAPHIC IMAGE ANALYSIS HOMEPAGE, 2009).

Cada imagem da base possui uma etiqueta descritiva composta por colunas que indicam: (i) o identificador do exame, (ii) a densidade do tecido mamário, podendo ser F (gorduroso), G (gorduroso-glandular) ou D (denso-glandular), (iii) o tipo de anormalidade presente, como calcificações (CALC), massas circunscritas (CIRC), massas espiculadas (SPIC), distorções arquitetônicas (ARCH), assimetrias (ASYM), outras massas mal definidas (MISC) ou ainda casos normais (NORM), (iv) a gravidade da anormalidade, com rótulos B (benigno) ou M (maligno), e (v-vi) as coordenadas centrais da lesão (x, y), seguidas de (vii) um raio estimado em pixels de um círculo que engloba a região de interesse (MADER, 2018).

As imagens estão organizadas em pares, correspondendo às mamas esquerda e direita de cada paciente. Em casos de calcificações amplamente distribuídas, as coordenadas centrais e raios podem estar ausentes. A origem das coordenadas está localizada no canto inferior esquerdo da imagem.

4.2.2 Experimento

O experimento envolve o treinamento e avaliação de uma rede neural convolucional (CNN), comparando imagens originais com aquelas pré-processadas pela transformada *Wavelet* multinível. Os dados serão divididos em conjuntos de treinamento, validação e teste, e o desempenho avaliado por métricas como acurácia, sensibilidade e especificidade.

Dois cenários experimentais serão considerados: (i) CNN com *transfer learning* (aprendizado por transferência), utilizando arquiteturas ResNet-18, ResNet-34 e ResNet-50 em imagens originais; (ii) CNN com *transfer learning* (ResNet-18/34/50) aplicada às imagens com *Wavelet*.

4.2.3 Implementação

A implementação será realizada em *Python*, utilizando a biblioteca *PyTorch* para construção e treinamento da CNN, e *PyWavelets* para aplicar a decomposição *Wavelet* multinível nas imagens. A reprodutibilidade será garantida pela disponibilização do código-fonte em repositório público no GitHub, permitindo que os experimentos possam ser replicados por outros pesquisadores.

4.3 RESULTADOS ESPERADOS

Espera-se que a utilização da transformada *Wavelet* como técnica de pré-processamento melhore o desempenho da rede neural convolucional na detecção de nódulos mamários, especialmente em tecidos densos classificados como BI-RADS 3 e 4. Acredita-se que a decomposição da imagem em diferentes níveis de resolução permitirá à rede identificar padrões sutis com maior precisão.

Ao comparar os modelos treinados com e sem o uso da *Wavelet*, espera-se observar um aumento nas métricas de avaliação, indicando uma redução de falsos positivos e negativos. Além disso, o projeto busca evidenciar a viabilidade do uso de ferramentas de código aberto e bases públicas na construção de soluções de apoio ao diagnóstico por imagem, contribuindo para a democratização do acesso à tecnologia na área médica.

Por fim, espera-se que os resultados obtidos reforcem a importância do pré-processamento adequado de imagens médicas e do uso de IA na triagem de exames mamográficos, promovendo avanços na detecção precoce do câncer de mama.

4.4 CRONOGRAMA

O Quadro 1 descreve o planejamento das atividades para o desenvolvimento deste trabalho. A organização segue a estrutura do processo de HCML, adotado como base metodológica. As etapas foram distribuídas de forma sequencial, iniciando pela fundamentação teórica e revisão da literatura, passando pela definição dos requisitos e preparação dos dados. As fases experimentais ocorrem a partir de agosto, com o treinamento, avaliação e aplicação do modelo. Por fim, o cronograma contempla a exportação dos resultados, análise crítica, escrita da conclusão e preparação para a apresentação final.

Quadro 1 – Cronograma de atividades

Atividade	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Introdução	x	x	x								
Fundamentação Teórica	x	x	x	x							
Revisão da Literatura					x	x					
Metodologia					x	x					
Análise dos Requisitos					x						
Preparação dos Dados						x	x				
Treinamento do Modelo							x	x			
Avaliação do Modelo								x	x		
Predição									x		
Exportação de Resultados										x	
Discussão dos Resultados										x	x
Conclusão										x	x
Preparação e Defesa do TCC											x

Fonte: Elaborada pela autora.

REFERÊNCIAS

- AGUIAR NETO, Décio Gonçalves de. **Transferência de conhecimento utilizando aprendizado profundo para classificação de imagens histopatológicas**. Quixadá, Brasil, 2017. Orientador: Prof. Dr. Paulo de Tarso Guerra Oliveira. Disponível em: <https://repositorio.ufc.br/bitstream/riufc/29515/1/2017_tcc_dganaguiar.pdf>.
- BANERJEE, Sheekar; KABIR, Humayun. An introductory implementation of breast cancer detection from mammograms and pixel intensity with Efficient-Net and other neural nets. **Cold Spring Harbor Laboratory**, 2024. Preprint. DOI: 10.1101/2024.05.04.592536. Disponível em: <<https://doi.org/10.1101/2024.05.04.592536>>. Acesso em: 28 jun. 2025.
- BLAHOVÁ, Lenka; KOSTOLNÝ, Jakub; CIMRÁK, Ivan. Neural network-based mammography analysis: augmentation techniques for enhanced cancer diagnosis — a review. **Bioengineering**, v. 12, p. 232, 2025. DOI: 10.3390/bioengineering12030232. Disponível em: <<https://doi.org/10.3390/bioengineering12030232>>. Acesso em: 28 jun. 2025.
- BRAVO, Barbara Silva et al. Câncer de mama: uma revisão de literatura/ Breast cancer: a literature review. **Brazilian Journal of Health Review**, v. 4, n. 3, p. 14254–14264, jun. 2021. DOI: 10.34119/bjhrv4n3-357. Disponível em: <<https://ojs.brazilianjournals.com.br/ojs/index.php/BJHR/article/view/32101>>.
- CADRIN-CHÊNEVERT, Alexandre. Unleashing the Power of Deep Learning for Breast Cancer Detection through Open Mammography Datasets. **Radiology: Artificial Intelligence**, v. 5, n. 2, e220294, 2023. DOI: 10.1148/ryai.220294. Disponível em: <<https://doi.org/10.1148/ryai.220294>>.
- CUNHA, Leonardo Cardoso da. **Redes neurais convolucionais e segmentação de imagens: uma revisão bibliográfica**. 2020. Disponível em: <https://www.monografias.ufop.br/bitstream/35400000/2872/6/MONOGRAFIA_RedNeuraisConvolucionais.pdf>.
- DOMINGUES, M. O. et al. Explorando a transformada wavelet contínua. **Revista Brasileira de Ensino de Física**, v. 38, n. 3, p. 1–12, 2016. DOI: 10.1590/1806-9126-RBEF-2016-0019. Disponível em: <<https://doi.org/10.1590/1806-9126-RBEF-2016-0019>>.
- FERNEDA, Edberto. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, v. 35, n. 1, p. 25–30, 2006. DOI: 10.1590/S0100-19652006000100003. Disponível em: <<https://www.scielo.br/j/ci/a/SQ9myjZWLxnyXfstXMgCdch/?format=pdf&lang=pt>>.
- FREITAS, Andréa Gonçalves de et al. Mamografia Digital: Perspectiva Atual e Aplicações Futuras. **Radiologia Brasileira**, v. 39, n. 4, p. 287–296, 2006. Atualização. DOI: 10.1590/S0100-39842006000400012.

- GIL, Antônio Carlos. **Como Elaborar Projetos de Pesquisa**. 2002. Disponível em: <https://files.cercomp.ufg.br/weby/up/150/o/Anexo_C1_como_elaborar_projeto_de_pesquisa_-_antonio_carlos_gil.pdf>.
- GOSWAMI, Jaideva C.; CHAN, Andrew K. **Fundamentals of Wavelets: Theory, Algorithms, and Applications**. John Wiley & Sons, 1999. ISBN 978-0-471-25578-1.
- ISIN, Ali; OZDALILI, Selen. Cardiac arrhythmia detection using deep learning. **Procedia Computer Science**, v. 120, p. 268–275, 2017. DOI: 10.1016/j.procs.2017.11.238. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S187705091732450X>>.
- JADOON, M. et al. Three-class mammogram classification based on descriptive CNN features. **BioMed Research International**, Hindawi, v. 2017, p. 1–11, 2017.
- LEITE, Francisco E. A.; HENRIQUES, Marcos V. C.; CUNHA, Maytê T. N. Análise de Imagens em Escalas Utilizando a Transformada Wavelet. **Anais do Encontro de Computação do Oeste Potiguar ECOP/UFERSA**, v. 1, n. 2, p. 59–66, 2018. Disponível em: <<https://periodicos.ufersa.edu.br/ecop/article/view/7903>>.
- MADER, Klemens. **MIAS Mammography Database**. 2018. <https://www.kaggle.com/datasets/kmader/mias-mammography>. Disponível no Kaggle. Base com imagens mamográficas digitalizadas e anotações clínicas da Mammographic Image Analysis Society (MIAS). Acesso em: 30 jun. 2025.
- MAGRINI, Luciano Aparecido. Funções wavelet e transformada wavelet contínua: representação simultânea nos domínios do tempo e da frequência. **C.Q.D. – Revista Eletrônica Paulista de Matemática**, v. 19, p. 17–32, 2020. DOI: 10.21167/cqdvol19202023169664lam1732. Disponível em: <<https://www.fc.unesp.br/Home/Departamentos/Matematica/revistacqd2228/v19a03-funcoes-wavelet-e-transformada-wavelet-continua.pdf>>.
- MAMMOGRAPHIC IMAGE ANALYSIS HOMEPAGE. **Databases – MammoImage.org**. 2009. <https://www.mammoimage.org/databases/>. Acessado em 30 de junho de 2025.
- MARTINS, R. Mayor. **Perceptron: projeto e implementação**. 2025. Website pessoal. Acesso em 26 de junho de 2025. Disponível em: <<https://rmayormartins.github.io/tools-ia-projects/perceptron.html>>.
- MARTINS, Ramon Mayor et al. Exploring the relationship between learning of machine learning concepts and socioeconomic status background among middle and high school students: a comparative analysis. **ACM Transactions on Computing Education**, v. 24, n. 3, p. 1–31, set. 2024. DOI: 10.1145/3680288. Disponível em: <<https://doi.org/10.1145/3680288>>. Acesso em: 20 jun. 2025.
- MIYAZAKI, Caio Kioshi. **Redes neurais convolucionais para aprendizagem e reconhecimento de objetos 3D**. 2017. Disponível em: <https://bdta.abcd.usp.br/directbitstream/ee692ea6-3d9c-4d48-92a6-c672e8dbef07/Miyazaki_caio_tcc.pdf>.

MUPPARAJU, Shivani; JAHNAVI, B. Naga Venkata Satya Durga. Comparison of Various Thresholding Techniques of Image Denoising. **International Journal of Engineering Research & Technology (IJERT)**, v. 2, n. 9, p. 3293–3298, 2013. Disponível em: <<https://www.ijert.org/research/comparison-of-various-thresholding-techniques-of-image-denoising-IJERTV2IS90812.pdf>>.

OYELADE, Olaide N.; EZUGWU, Absalom E. A novel wavelet decomposition and transformation convolutional neural network with data augmentation for breast cancer detection using digital mammogram. **Scientific Reports**, v. 12, p. 5913, 2022. DOI: 10.1038/s41598-022-09905-3. Disponível em: <<https://www.nature.com/articles/s41598-022-09905-3>>. Acesso em: 28 jun. 2025.

PASSIG E SILVA, Eduarda. **Deteção de nódulos em imagens de mamografia usando wavelet e inteligência artificial**. 2022. TCC (Engenharia de Telecomunicações) – Instituto Federal de Santa Catarina – Campus São José. Disponível em: <https://wiki.sj.ifsc.edu.br/images/0/09/TCC_68_EDUARDA_PASSIG_E_SILVA.pdf>.

RASHEED, Ahmed et al. **Use of transfer learning and wavelet transform for breast cancer detection**. 2021. arXiv preprint. arXiv: 2103.03602 [eess.IV]. Disponível em: <<https://arxiv.org/abs/2103.03602>>. Acesso em: 28 jun. 2025.

ROSA, Andrey Adriano da. **Reconhecimento por imagem de lances de xadrez com visão computacional e redes neurais convolucionais**. 2025. Disponível em: <https://wiki.sj.ifsc.edu.br/images/a/a0/TCC_ANDREY_ADRIANO_DA_ROSA.pdf>.

SECHOPOULOS, Ioannis; TEUWEN, Jonas; MANN, Ritse. Artificial intelligence for breast cancer detection in mammography and digital breast tomosynthesis: State of the art. **Seminars in Cancer Biology**, v. 72, p. 214–225, 2021. DOI: 10.1016/j.semcancer.2020.06.002. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1044579X20301358>>.

SILVA JUNIOR, Edvaldo Castro da. **Construção e análise de rede neural convolucional com neurônios pulsados para classificação de imagens**. 2022. Dissertação de Mestrado – Universidade de São Paulo, Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto.

SOUSA, Maria Angélica Zucareli. **Desenvolvimento de um objeto simulador de mama: investigações da percepção visual da imagem e do desempenho de esquemas CADx**. 2017. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. Tese de Doutorado.

TEARE, Peter et al. Malignancy detection on mammography using dual deep convolutional neural networks and genetically discovered false color input enhancement. **Journal of Digital Imaging**, Springer, v. 30, n. 4, p. 499–505, 2017.

VERY TECHNOLOGY. **Machine Learning Algorithms: What is a Neural Network?**

Acesso em: 26 jun. 2025. n.d. Disponível em: <<https://www.verytechnology.com/insights/machine-learning-algorithms-what-is-a-neural-network>>.