

INSTITUTO FEDERAL DE SANTA CATARINA

EDUARDA PASSIG E SILVA

**Deteccção de nódulos em imagens de mamografia
usando Wavelet e Inteligência Artificial**

São José - SC

Fevereiro/2023

DETECÇÃO DE NÓDULOS EM IMAGENS DE MAMOGRAFIA USANDO WAVELET E INTELIGÊNCIA ARTIFICIAL

Monografia apresentada ao Curso de Engenharia de Telecomunicações do Campus São José do Instituto Federal de Santa Catarina para a obtenção do diploma de Engenheiro de Telecomunicações.

Orientadora: Prof. Elen Macedo Lobato, Dra.

Coorientador: Prof. Ramon Mayor Martins,
Me

São José - SC

Fevereiro/2023

EDUARDA PASSIG E SILVA

DETECÇÃO DE NÓDULOS EM IMAGENS DE MAMOGRAFIA USANDO WAVELET E INTELIGÊNCIA ARTIFICIAL

Este trabalho foi julgado adequado para obtenção do título de Engenheira de Telecomunicações, pelo Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina, e aprovado na sua forma final pela comissão avaliadora abaixo indicada.

São José - SC, 13 de Fevereiro de 2023:

Prof. Elen Macedo Lobato, Dra.

Orientadora

Instituto Federal de Santa Catarina

Prof. Roberto W. Nóbrega, Dr.

Instituto Federal de Santa Catarina

Prof. Ana Paula Rosa Negri, Me.

Instituto Federal de Santa Catarina

Este trabalho é dedicado a meus pais que sempre me apoiaram.

AGRADECIMENTOS

Agradeço à minha orientadora que não desistiu de mim, mesmo quando eu queria desistir. Aos meus pais, que me ajudaram e incentivaram na minha trajetória. À minha irmã , à minha sogra e ao meu esposo que leram tantas versões deste trabalho como revisão e apoio. À todos, os meus mais profundos e sinceros agradecimentos.

*Educação é uma descoberta progressiva
de nossa própria ignorância.*
Voltaire

RESUMO

O câncer de mama é uma doença letal, caso não seja descoberta no início. Esta doença é normalmente diagnosticada através da análise de imagens de mamografia. Essas imagens mamográficas por serem muito ruidosas, devido a sua forma de aquisição, necessitam de técnicas que removam os ruídos. Uma técnica muito usada na remoção de ruído é conhecida como *wavelet denoising*. Já a inteligência artificial está sendo amplamente usada, inclusive em hospitais, para auxiliar no diagnóstico de câncer de mama. Este trabalho tem o intuito de unir estas duas vertentes de pesquisa e verificar se há uma melhora significativa na detecção de calcificações utilizando aprendizado de máquina para classificar as imagens após ter passado por um processo de remoção de ruído via *wavelet*. Ao final desse trabalho são apresentados os resultados deste estudo.

Palavras-chave: aprendizado de máquina. câncer de mama. diagnóstico. wavelet.

ABSTRACT

Breast cancer is a lethal disease if not caught early. This disease is usually diagnosed by analyzing mammography images. Because these mammographic images are very noisy, due to the way they are acquired, they require techniques that remove noise. A widely used noise removal technique known is *wavelet denoising*. Artificial intelligence is being widely used, including in hospitals, to aid in the diagnosis of breast cancer. This work aims to unite these two lines of research and verify if there is a significant improvement in the detection of calcifications using machine learning to classify the images after having gone through a noise removal process via *wavelet*. At the end of this work, the results of this study are presented.

Keywords: machine learning. breast cancer. diagnosis. wavelet.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exame de mamografia	26
Figura 2 – Abstração de imagem digital	27
Figura 3 – Transformada de Fourier representada na frequência e no tempo	28
Figura 4 – Transformada de <i>Wavelet</i> representada na frequência e no tempo	28
Figura 5 – Comparação entre componente de <i>Fourier</i> e <i>Wavelet</i> 10 db	29
Figura 6 – Exemplo de Famílias Wavelet	29
Figura 7 – Decomposição em componentes	31
Figura 8 – Exemplificação de Componentes de limiarização suaves e duras $\lambda = 0.1$	32
Figura 9 – Treinamento de aprendizado de máquina	33
Figura 10 – Exemplificação de matriz de confusão	34
Figura 11 – Exemplo de Redes neurais	35
Figura 12 – Exames de mamografias com as diferentes classificações	36
Figura 13 – exemplo de Rede Neural Convolucional do inglês <i>Convolutional Neural Network</i> ou <i>ConvNet</i> (CNN) (SELVATHI; POORNILA, 2017) adaptada	36
Figura 14 – Distribuição de imagens dentro do banco (SUCKLING, 1994)	37
Figura 15 – Matriz de confusão sem pré processamento	39
Figura 16 – Função Biorthogonal 1.5	39
Figura 17 – Função Biorthogonal 1.5 relação de filtros	40
Figura 18 – Sinais <i>Wavelet</i> mães	41
Figura 19 – Matriz de confusão removendo o fundo	46
Figura 20 – Matriz de confusão, com pré processamento, nível 8, Biorthogonal 3.6 e suave	47
Figura 21 – Matriz de confusão com pré processamento, com nível 8 de decomposição, Biorthogonal 3.6, suave e removendo o fundo	47

LISTA DE TABELAS

Tabela 1	– Resultados das métricas sem pré-processamento	38
Tabela 2	– Resultados replicando o trabalho para 2 categorias	43
Tabela 3	– Bayer dura Biorthogonal 1.5 por nível de decomposição	43
Tabela 4	– Bayer dura Biorthogonal 3.6 por nível de decomposição	44
Tabela 5	– Bayer suave Biorthogonal 3.6 por nível de decomposição	44
Tabela 6	– Bayer dura Haar por nível de decomposição	44
Tabela 7	– Symlets 2	45
Tabela 8	– Bayer dura Symlets 9 por nível de decomposição	45
Tabela 9	– Coif 3 Bayer	45
Tabela 10	– Métricas de bayer removendo o fundo com limiarização suave e nível de decomposição 8	46

LISTA DE ABREVIATURAS E SIGLAS

Covid-19	<i>Corona Virus Disease 2019</i>	23
CNN	Rede Neural Convolucional do inglês <i>Convolutional Neural Network</i> ou <i>Conv-Net</i>	13
mini-MIAS	<i>The Mammographic Image Analysis Society</i>	37
SNR	<i>Relação Sinal Ruído</i> do inglês <i>Signal-To-Noise Ratio</i>	32
FFT	transformada rápida de <i>Fourier</i> do inglês <i>Fast Fourier Transformer</i>	28

LISTA DE SÍMBOLOS

σ	Letra grega sigma
α	Letra grega alfa
ϕ	Letra grega Fi
ψ	Letra grega Psi
λ	Letra grega Lambda

SUMÁRIO

1	INTRODUÇÃO	23
1.1	Objetivos Gerais	23
1.2	Objetivos Específicos	23
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	Câncer de Mama	25
2.2	Mamografia	25
2.3	Imagens Digitais	25
2.4	Processamento de Imagens	26
2.4.1	Remoção de fundo	26
2.4.2	Transformada Wavelet	28
2.4.2.1	Wavelet Discreta	30
2.4.2.2	Banco de filtros	30
2.4.2.3	Wavelet Denoising	31
2.5	Inteligência Artificial	33
2.5.1	Aprendizado de máquina	33
2.5.2	Aprendizado profundo	35
3	DESENVOLVIMENTO	37
3.1	Base de dados	37
3.2	Classificações com Deep Learning	38
3.3	Classificação com Deep Learning + Wavelet	38
4	RESULTADOS E DISCUSSÕES	43
4.0.1	Remoção de fundo	43
4.0.2	Resultado com famílias Wavelet	43
4.1	Discussões	45
4.1.1	Métodos de avaliação dos Resultados	45
5	CONCLUSÕES	49
5.1	Trabalhos futuros	49
	REFERÊNCIAS	51

1 INTRODUÇÃO

De acordo com a Sociedade Brasileira de Mastologia (2020), a pandemia de *Corona Virus Disease 2019* (Covid-19) e as alterações na saúde das mulheres, foram alguns dos fatores que contribuíram para o aumento de casos de câncer de mama. Tornando-se, assim, a forma mais comum da doença em aspecto global.

O câncer de mama é o câncer que mais causa morte entre a população feminina. Essa mortalidade pode diminuir se for diagnosticada em estado inicial da doença. Para o diagnóstico, geralmente são utilizados os exames de mamografia, no qual são geradas imagens utilizando baixas dosagens de raios-x, o que ocasiona imagens de baixa resolução, contendo muitos ruídos. (OLIVEIRA, 2016).

Uma técnica comumente utilizada na identificação e classificação de formas em imagens é o aprendizado de máquina. Na área da saúde, o trabalho de Selvathi e Poornila (2017) apresenta uma comparação de técnicas de aprendizado de máquina. Esse trabalho foi usado como base para obter novos tipos de classificação. Além dessa modificação, optou-se em utilizar o processamento de imagens através da técnica de limiarização, e remoção de ruído a partir da transformada *Wavelet* para obter imagens mais nítidas. Desta forma, espera-se que o algoritmo de classificação de imagens utilizando aprendizado de máquina, consiga melhorar seu funcionamento. Os trabalhos de AraÚjo (2018) e Oliveira (2016) apresentaram a eficácia da remoção de ruídos utilizando *Wavelets* em imagens mamográficas. Esses trabalhos foram usados como base para definições de parâmetros das famílias *Wavelet*. Assim garantindo que os melhores resultados sejam adquiridos.

1.1 Objetivos Gerais

Aplicar um pré-processamento utilizando a remoção de ruído a partir da transformada *wavelet* em imagens de mamografias. E usá-las em um código com aprendizado de máquina da tese de mestrado do Selvathi e Poornila (2017), que faz o reconhecimento e classificação de exames de mamografias, com o objetivo de melhorar os resultados unindo essas duas técnicas. Com isso, auxiliando o diagnóstico precoce de câncer mamário.

1.2 Objetivos Específicos

- Replicar o trabalho de mestrado do Selvathi e Poornila (2017);
- Modificar o código para reconhecer ou não nódulos, pois este trabalhava com a

classificação de imagens como casos malignos, benignos, e normais;

- Inserir o pré-processamento com remoção de ruídos utilizando transformada *Wavelet*, variando as famílias, os níveis de decomposição e a formação dos limiares;
- Remover o fundo da imagem para que não haja outras interferências na imagem que não seja o objeto de estudo, no caso a mama;
- Usar métricas para avaliar o desempenho.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Câncer de Mama

O câncer de mama, como muitos outros tipos de câncer, é uma disfunção da divisão celular que acarreta em um crescimento anormal do tecido, que afeta vários tipos de células do corpo humano. Nas mulheres, 28% dos casos de câncer são mamários de acordo com Oncoguia (2020).

O melhor cenário seria encontrar a doença nos estágios iniciais, por ter maior chance de tratamento, como dito por INCA (2021b). Existem vários exames para o diagnóstico, tais como ultrassonografia, ressonância magnética e a tomossíntese. Por conta do envelhecimento da mama, elas se tornam mais glandulares, assim, outros exames como a ultrassonografia não funcionariam tão bem pois as glândulas distorcem as imagens, de acordo com INCA (2021a). Por esse motivo, um dos exames principais é a mamografia, em que se obtém a melhor imagem das mamas sem interferência das glândulas.

Os formatos e tamanhos dos nódulos podem indicar se são benignos ou malignos conforme as imagens, quanto mais regulares, ovais e com as bordas bem definidas, tem uma maior indicação de serem benignos. Sendo que, apenas com mais exames e acompanhamento médico para ter um real diagnóstico de acordo com Nubia (2022).

2.2 Mamografia

De acordo com Selvathi e Poornila (2017), a mamografia é um exame radiológico que utiliza baixas doses de radiação ionizante para obter uma imagem com foco na mama, em que é possível observar um fundo preto, e em branco a mama, suas calcificações ou massa, como nódulos ou cistos. Na Figura 1 pode-se verificar como é feito o exame.


O equipamento é um raio X, onde a imagem é gerada a partir de uma diferença de coeficientes de atenuação linear dos tecidos que a mama contém. Assim mostrando a separação de formas e densidades no exame. No emissor são disparados elétrons que dependendo da trajetória chegam com mais ou menos velocidade, definindo a intensidade da cor no detector (ARAÚJO, 2018).

2.3 Imagens Digitais

Uma imagem pode ser considerada como apenas um sinal, que se ordena no formato de uma ou mais matrizes, onde cada coordenada $f(x,y)$ é um número que representa a

Figura 2 – Abstração de imagem digital

(a) Como nos vemos uma imagem



(b) Como o computador vê as imagens

119	122	124	126	130	129	128	126	122	120	119	116	116	116
124	120	122	125	126	128	129	128	124	120	116	120	114	110
122	122	123	123	121	125	128	127	126	121	119	117	114	110
121	122	125	124	121	121	121	123	123	124	124	120	115	109
119	118	119	117	118	119	116	120	121	122	120	119	115	113
117	117	116	115	113	116	114	115	117	117	117	114	116	115
111	110	111	111	110	110	107	109	112	113	115	115	110	111
105	106	105	106	104	104	103	105	108	109	109	112	112	109
102	103	106	105	104	103	104	106	102	103	105	110	109	108
101	101	100	104	106	105	102	105	103	103	108	111	110	108
100	102	101	104	104	104	102	105	105	104	107	107	110	109
100	104	103	104	103	104	102	102	104	104	105	110	108	108
101	102	102	104	99	102	103	103	103	103	105	108	111	109
102	101	104	103	103	102	105	105	104	104	105	107	110	107
102	101	105	101	102	105	104	106	104	108	108	106	108	108
101	103	104	103	103	105	106	106	110	109	110	108	112	110
99	102	103	103	104	103	105	106	107	109	110	110	112	107
99	100	101	103	104	105	105	106	108	108	110	110	111	107
99	101	101	101	102	103	104	104	107	109	108	107	110	107
104	102	102	100	104	103	107	105	107	109	105	106	106	105
105	103	101	100	101	102	104	106	106	107	104	102	107	104
101	104	101	100	102	99	103	106	105	107	105	101	104	103

Fonte: O próprio autor

$$B(x, y) = \begin{cases} 1, & \text{Se } I(x, y) \geq \text{limiar} \\ 0, & \text{Caso contrário} \end{cases} \quad (2.1)$$

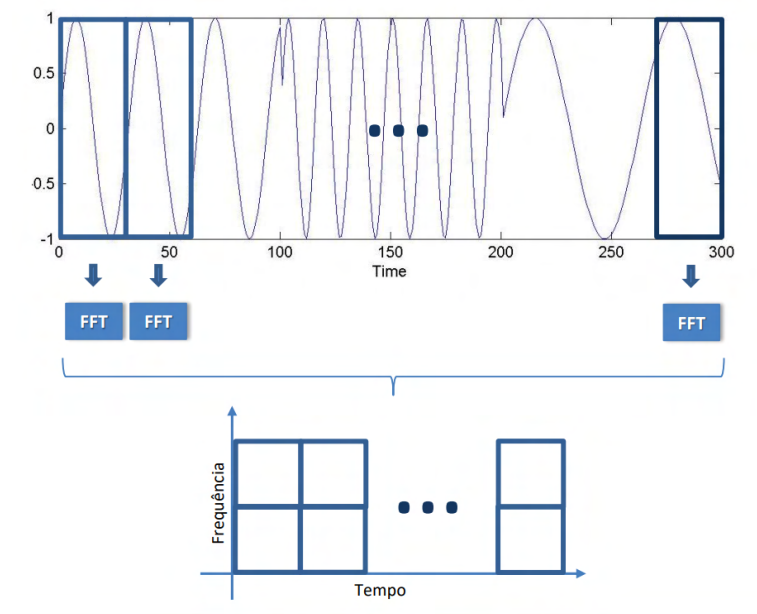
Após obter-se essa imagem binarizada, esta é multiplicada aos valores reais da imagem. Assim, obtém-se valores definidos como 1, que continuam com o valor original da imagem, sendo os demais substituídos por 0, assim retirando o fundo, redefinindo o valor na matriz como 0.

Por ser uma imagem onde o fundo é separado, com um grande contraste em escalas de cinza, torna-se fácil a identificação do mesmo. Assim, ao multiplicar cada pixel pelo valor da imagem binária, consegue-se a imagem original sem o fundo.

2.4.2 Transformada Wavelet


A Transformada *Wavelet* foi desenvolvida para solucionar um problema da transformada de *Fourier* com a representação de sinais não variantes no tempo, Figura 3 em que se mostra as janelas transformada rápida de *Fourier* do inglês *Fast Fourier Transformer* (FFT), não conseguindo ser definido um tamanho padrão para elas, para conseguir decompor o sinal teria que se dividir o mesmo em janelas muito pequenas, não conseguindo informações relevantes sobre do sinal (ARAÚJO, 2018).

Figura 3 – Tansformada de Fourier representada na frequência e no tempo



Fonte: Vieira (2010)

Figura 4 – Tansformada de *Wavelet* representada na frequencia e no tempo



Fonte: Vieira (2010)

A transformada *Wavelet* tem sua fundamentação muito parecida com a transformada de FFT. Nela, ao invés de dividir um sinal em componentes senoidais, é subdividida em componentes *Wavelets*, que são ondas que se atenuam em um curto espaço de tempo, conforme a comparação mostrada na Figura 5 (DIAS, 2003).

A transformada *Wavelet* contínua pode ser definida como Equação 2.2, onde "a" indica se essa função foi dilatada ou comprimida e "b" representa o deslocamento no tempo e ψ é uma *Wavelet* mãe (ARÊDES, 2009).

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

, $a \neq 0$ (2.2)

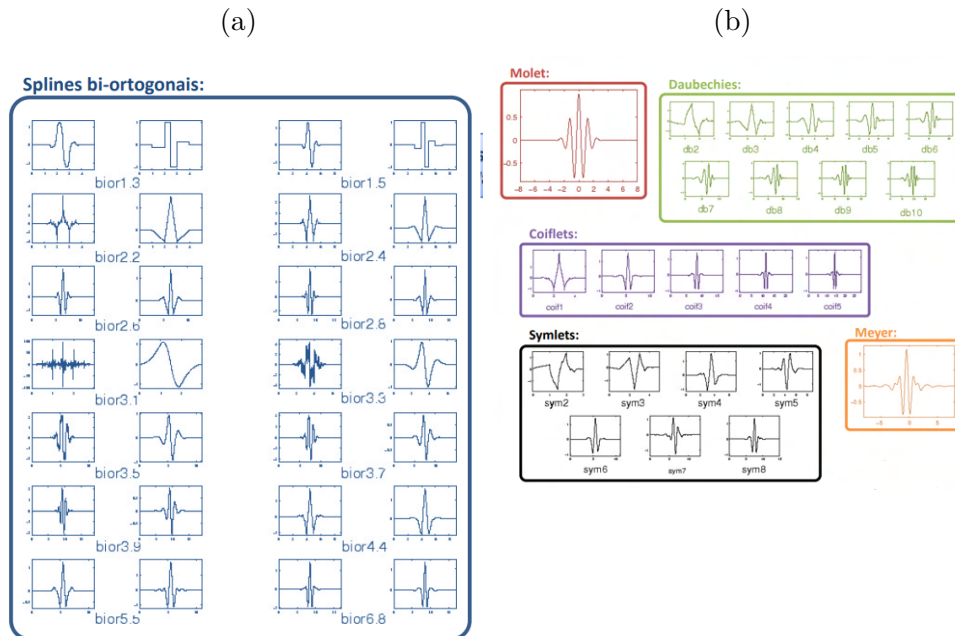
Figura 5 – Comparação entre componente de *Fourier* e *Wavelet* 10 db



Fonte: Dias (2003)

Wavelets mães são sinais que ao serem deslocados, multiplicados, convoluídos e entre outras transformações formam uma família. Alguns exemplos de gráficos das famílias podem se ver na Figura 6 (VIDAKOVIC; MUELLER, 1991).

Figura 6 – Exemplo de Famílias Wavelet



Fonte: Vieira (2010)

Para ser um sinal passível de se tornar um *Wavelet* mãe é necessário : (ARÊDES, 2009)

- Possuir energia finita.
- Apresentar certo grau de regularidade (suavidade);
- Apresentar convergência ou ser zero no infinito. seus maiores e menores valores tendem a zero;

- Possuir um certo número (p) de momentos nulos;
- Atender à condição de admissibilidade que significa ter a área igual a 0;
- Ter suporte compacto, no tempo e na frequência, que consiste em uma pequena mudança no domínio da frequência gera pequenas modificações no tempo em pontos bem definidos.

2.4.2.1 Wavelet Discreta

A transformada discreta é utilizada em sistemas digitais por conta do sinal digital ser uma amostragem. Esta é definida pela Equação 2.3 onde Φ é uma função escalar que depende de ψ (SALOMON, 2000).

$$f(t) = \sum_{k=-\infty}^{\infty} c_k \phi(t - k) + \sum_{k=-\infty}^{\infty} \sum_{j=0}^{\infty} d_{j,k} \psi(2^j t - k) \quad (2.3)$$

Em que ϕ está associado às baixas frequências do sinal e ψ as altas. Desta forma pode-se escrever as funções 2.4 e 2.5.

$$h_n = \langle \psi_{0,0}, \phi_{1,n} \rangle \text{ e } \psi(t) = \sqrt{2} \sum_{n \in \mathbb{Z}} h_n \phi(2t - n) \quad (2.4)$$

$$g_n = \langle \phi_{0,0}, \phi_{1,n} \rangle \text{ e } \phi(t) = \sqrt{2} \sum_{n \in \mathbb{Z}} g_n \phi(2t - n). \quad (2.5)$$

2.4.2.2 Banco de filtros


Com as séries h e g definidas anteriormente, estas são utilizadas como filtros passa-alta e passa-baixa respectivamente para serem aplicados à entrada x como uma convolução como na Equação 2.6, onde $c = \{c_n\}_{n \in \mathbb{Z}}$ e $d = \{d_n\}_{n \in \mathbb{Z}}$ são aproximações do sinal original com detalhes (SALOMON, 2000).

$$c(n) = \sum_k g(k)x(n - k) = g \star x \text{ e } d(n) = \sum_k h(k)x(n - k) = h \star x \quad (2.6)$$

Por divisão do sinal original em vários componentes de frequências, obtemos a possibilidade de analisar individualmente cada componente (DAUTOV; OZERDEM, 2018). A sucessão de aplicações de bancos de filtros pode gerar muitos dados, o que dificulta o processamento computacional pela utilização de memória, o que provoca o surgimento da subamostragem.

A Figura 7 mostra uma das formas em que a quantidade de componentes é dividida pela metade, onde "L" são os componentes de baixa frequência e os "H" são os componentes de alta frequência (DIAS, 2003).

Figura 7 – Decomposição em componentes



Fonte: Oliveira (2016)

2.4.2.3 Wavelet Denoising

O processo de remoção de ruídos por *Wavelet* trabalha usando os seguintes passos. Primeiramente, o sinal é decomposto em coeficientes *Wavelet* (Equação 2.7). Em seguida C , é aplicado na Equação 2.8 $D(C, \alpha)$ sendo ele o operador que representa o processo de remoção de ruído para um limiar α . Assim, ao se aplicar a transformada inversa, como visto na Equação 2.9, obtém-se o sinal inicial com os ruídos atenuados (DIAS, 2003).

$$C = W(x) \quad (2.7)$$

$$C_d = D(C, \alpha) \quad (2.8)$$

$$s(t) = W^{-1}(C_d) \quad (2.9)$$


A remoção de ruído apresentada em Equação 2.8 é uma limiarização, neste trabalho se apresentando por duas formas *Bayes* e *Visu*.

O *Visu*, definido pela Equação 2.10, é outra possibilidade onde σ é a variação de ruído e I é o número de pixels na imagem (MUPPARAJU et al., 2013), para a definição do limiar variando com a frequência. O máximo de qualquer valor I , pode ser dado por Equação 2.11 com a probabilidade se aproximando de 1, quanto maior o número de pixels na imagem aumenta, este tende a produzir uma estimativa excessivamente suavizada (DIAS, 2003).

$$x = \sigma \sqrt{2 \log I} \quad (2.10)$$

$$x = N(0, \sigma^2) \quad (2.11)$$

Figura 8 – Exemplificação de Componentes de limiarização suaves e duras $\lambda = 0.1$



Fonte: Oliveira (2016)

O encolhimento *Bayes* foca na inferência bayesiana estatística para definir seu encolhimento para cada banda de frequência. Ou seja, o valor esperado do erro quadrático médio, quando a *Relação Sinal Ruído do inglês Signal-To-Noise Ratio* (SNR) é muito menor que 1 é escolhido um pequeno valor na média mínima no tempo com o intuito de preservar a maior parte do sinal, quando o SNR é muito maior que 1 é escolhido um grande valor para a média máxima no tempo que não haja perda com dito por Mupparaju et al. (2013). Também chamado de encolhimento adaptativo por esse motivo.

Este limiar pode ser aplicado ainda de duas formas: *hard* está representada na Equação 2.12 e *soft* representada na Equação 2.13. Elas aplicam os limiares definidos como λ sendo o linear definido e " d " o componente do sinal (VIDAKOVIC; MUELLER, 1991). Para exemplificar melhor, na Figura 8 pode ser visto uma aplicação no sinal quando o limiar é 1.

$$T^{hard}(d, \lambda) = d1(|d| > \lambda) \quad (2.12)$$

$$T^{soft}(d, \lambda) = sng(d)\sqrt{d^2 - \lambda^2}1(|d| > \lambda) \quad (2.13)$$

Outro parâmetro é o nível de decomposição. Este é associado à quantidade de vezes em que o sinal é subdividido em componentes de alta e de baixa frequência. O nível de decomposição pode ser visto na Figura 7, onde nela está mostrado um nível de decomposição igual a 2. Este componente pode interferir na integridade do sinal original, removendo excessivamente partes do sinal desejado.

Como o objetivo é identificar claramente o acúmulo de valores em sinais bidimensionais, Mallat conclui que ao utilizar o método de *Wavelet* para o processo de remoção de ruído em imagens, é possível detectar a localização das bordas, permitindo assim, uma reconstrução com menor distorção visual (MALLAT; HWANG, 1992).

2.5 Inteligência Artificial

O reconhecimento de imagens é a identificação de padrões existentes nela. Para isso, é importante que as bordas das mesmas estejam destacadas para um melhor funcionamento do algoritmo.

A inteligência artificial é quando sistemas ou máquinas executam tarefas e podem aprimorar-se de acordo com as informações coletadas. Basicamente imitando uma inteligência humana (MITCHELL, 1997).

Principalmente na identificação de padrões, como por exemplo a lista de sugestões de mídias sociais, que identifica outros dados relacionados aos que você mais consumiu.

Na inteligência artificial existem várias vertentes, as mais utilizadas para análises de dados são o aprendizado de máquina e o aprendizado profundo.


2.5.1 Aprendizado de máquina

O aprendizado de máquina é uma técnica da inteligência artificial, focada em reconhecimento e separação de imagens, sons, vídeos, entre outros (MITCHELL, 1997).

Ele é dividido em duas principais áreas de acordo com a quantidade de interação humana, são elas a supervisionada e a não supervisionada. Neste trabalho, focaremos no aprendizado supervisionado, que consiste em categorias pré-definidas, onde os itens para o aprendizado já estão classificados.

Separando os itens por similaridade, por exemplo, como existem vários dados já classificados, encontra-se uma função que separa corretamente os dados, como na Figura 9, onde são testadas várias funções, e a que melhor separa os dados é escolhida.

Figura 9 – Treinamento de aprendizado de máquina



Fonte: Lama (2016)

Esta tecnologia já está sendo utilizada em hospitais, nos casos mais urgentes, para sinalização de oclusão de grandes artérias no cérebro, usando imagens radiológicas (RODRIGUES et al., 2021). A função escolhida tem como resultado a quantidade de imagens que foram classificadas corretas ou incorretas, mais conhecida como matriz de confusão, por exemplo na Figura 10

Figura 10 – Exemplificação de matriz de confusão

(a) Matriz de confusão com resultados (b) Matriz de confusão genérica

	Gato	Não Gato
Gato	3	1
Não Gato	2	4

	Gato	Não Gato
Gato	VP	FP
Não Gato	FN	VN

Fonte: O próprio autor.

Onde as variáveis genéricas na Figura 10b significam :

- VP : verdadeiro positivo, onde foi classificado como positivo e é positivo;
- FP : falso positivo, onde foi classificado como positivo porém era negativo;
- FN : falso negativo, onde foi classificado como negativo porém era positivo;
- VN : verdadeiro negativo, onde foi colocado como negativo e era negativo.

A partir destas definições, é possível extrair métricas para escolher o melhor sistema. A principal delas é a acurácia, que é definida pela equação que permite verificar a porcentagem de acertos, retirada do Falconí, Pérez e Aguilar (2019) definida pela Equação 2.14

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.14)$$

A precisão avalia qual proporção de identificações positivas foram realmente corretas. Esta pode ser definida como a Equação 2.15.

$$precisão = \frac{VP}{VP + FP} \quad (2.15)$$

O recall mostra a quantidade de positivos que foram classificados corretamente. Este parâmetro é para mostrar a efetividade de prever verdadeiros positivos, isto sendo a classe que é mais importante. Como a Equação 2.16

$$Recall = \frac{VP}{VP + FN} \quad (2.16)$$

F1 Score mostra o balanço entre precisão e recall com a Equação 2.17.

$$F1Score = 2 * \frac{recall * precisão}{recall + precisão} \quad (2.17)$$


Em casos de mais de uma classe para os cálculos, é mais apropriado definir a classe a fazer a comparação como positiva, e as demais como negativa, assim forçando a análise de cada classe separadamente.

2.5.2 Aprendizado profundo

O aprendizado profundo é um processo que utiliza repetidamente a árvore de tomada de decisão do aprendizado de máquina, descartando algumas das calcificações que não foram muito repetidas. Assim, a máquina com o próprio resultado pode re-processar os dados quantas vezes forem necessárias (CARVALHO, 2022).

Na Figura 11 é mostrado como as funções escolhidas podem recriar outras funções subsequentes e, se a maioria das funções retorna a uma classificação, esta é a escolhida.

Figura 11 – Exemplo de Redes neurais




Fonte: Carvalho (2022)

Na primeira parte do processo de aprendizado, o mais importante é a detecção de se existe ou não um acúmulo de células, como por exemplo na Figura 12; Depois, classifica-las se são benignas como calcificações e cistos, ou malignas (SELVATHI; POORNILA, 2017).

Um dos mais comuns códigos de inteligência é o Rede Neural Convolutacional do inglês *Convolutional Neural Network* ou *ConvNet* (CNN), que é basicamente um sistema baseado em convoluções e sub amostragens e depois a junção das imagens aplicadas subsequentemente, como pode ser vista na figura 13. O objetivo da convolução é agrupar camadas e reduzir as imagens de entrada em um formato simples, suficiente para serem processadas pelas camadas. Isso permite que as CNNs primeiro foquem em recursos de baixo nível, que são progressivamente montados em recursos de alto nível ou características, à medida que se aprofundam. A camada de junção se baseia em uma soma ponderada de bits da imagem.

Figura 12 – Exames de mamografias com as diferentes classificações

(a) Exame de mamografia normal (b) Exame de mamografia com câncer



Fonte: (JIANG et al., 2001)

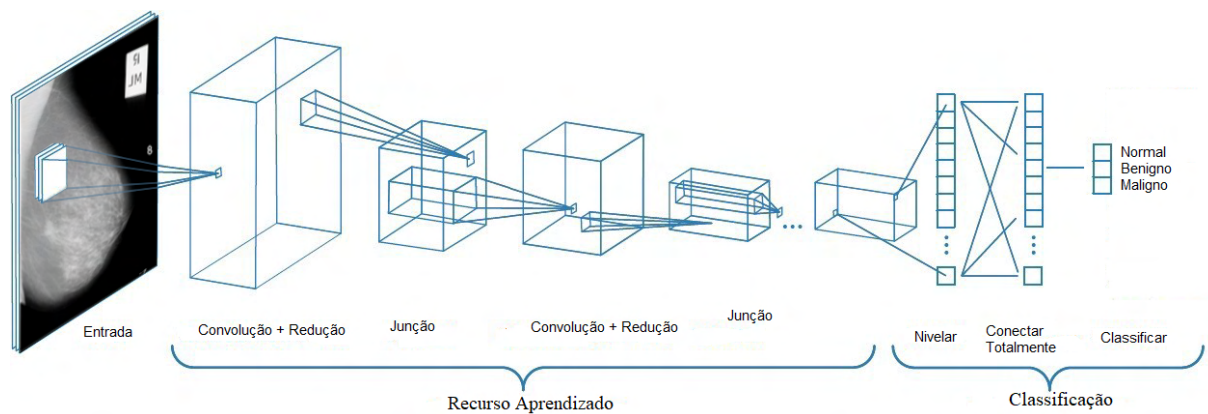


Figura 13 – exemplo de CNN (SELVATHI; POORNILA, 2017) adaptada

3 DESENVOLVIMENTO

A pesquisa se baseou na monografia Selvathi e Poornila (2017), que tem como objetivo encontrar o método mais adequado de inteligência artificial, para a detecção de aglomerados de células em imagens de mamografias, classificando-as.

Por ter obtido um melhor resultado no trabalho de Selvathi e Poornila (2017), será utilizado o método CNN.


3.1 Base de dados

Inicialmente, o banco de dados escolhido é mantido pela Universidade do sul da Flórida, que contém dados de 2500 casos, onde cada caso contém 1 imagem de cada mama. (JIANG et al., 2001)

As imagens em que existe alguma calcificação possuíam uma imagem extra, que há o destaque de onde estão localizados, assim, tendo uma possibilidade de analisar as imagens em especificações de localização. Porém, o banco de dados continha uma grande quantidade de imagens que precisavam ser descomprimidas, e necessitavam de uma grande infraestrutura de memória computacional.

Por isso, foi escolhido o banco de imagens da *The Mammographic Image Analysis Society* (mini-MIAS), que contém 322 imagens de 1024 pixels x 1024 pixels distribuídas seguindo a proporção descrita na Figura 14.

Figura 14 – Distribuição de imagens dentro do banco (SUCKLING, 1994)



Fonte: O próprio autor.

3.2 Classificações com Deep Learning

Utilizando o código de inteligência artificial, que categoriza mamografias em benigna, maligna ou normal, de acordo com o formato ou a existência dos nódulos, o código desenvolvido na tese de Selvathi e Poornila (2017) que utiliza a biblioteca TensorFlow na linguagem de programação Python, que permite o uso de diversos algoritmos para a criação e treinamento de redes neurais.

A monografia de Selvathi e Poornila (2017) cita que o código com aprendizado, utilizando o banco de imagens mini-MIAS, encontra um problema ao ser treinado pela disparidade de quantidade de imagens benignas e malignas em comparação a quantidade normais muito maior, não sendo viável um treinamento adequado para estas três classificações. Ao selecionar apenas benignas e malignas, obteve-se uma acurácia de 63.96% que poderia ser melhor, caso houvesse um pré processamento restringindo as partes mais relevantes da imagem.

Assim, para este estudo temos o objetivo de detectar a presença ou não de calcificações, então foi editado para apenas uma classe as imagens benignas e malignas. Como o treinamento precisa ser proporcional para que não haja a necessidade de atribuição de pesos, as imagens normais foram selecionadas para a mesma quantidade. Utilizando estas classificações sem pré-processamento com o treinamento de 50% das imagens e as demais para o processo de teste, os resultados obtidos no teste estão na Tabela 1, e uma acurácia de 52,17%.

Tabela 1 – Resultados das métricas sem pré-processamento

Métricas	Precisão	Recall	F1Score
Detectados	0.52	0.56	0.54
Não Detectados	0.52	0.48	0.5

Fonte: O próprio autor.


Sua matriz de confusão vista na Figura 15 mostra o quanto não é preciso, tornando assim metade das imagens tanto normais ou as imagens com casos.

Ao se utilizar Aprendizado de Máquina, metade das figuras é utilizada para treinar o sistema e a outra metade para testar. Assim, as matrizes de confusão tem metade do total de imagens separadas com tal propósito.

3.3 Classificação com Deep Learning + Wavelet

O sistema de remoção de ruídos via transformada *Wavelet* trabalha com a criação de limiares. Estes são alterados por parâmetros que mudam a forma de obtenção e a sequência de passos para obter a imagem final.

Figura 15 – Matriz de confusão sem pré processamento




Fonte: O próprio autor.

Foi criado um código utilizando *Python* (linguagem de programação) por ser a mesma linguagem do código de classificação e ter funcionalidade muito parecida com o *Matlab*, que é focado em trabalhos com matrizes, porém com código aberto e de fácil acesso a qualquer usuário.

Neste existe a biblioteca *skimage* que contém várias funções de processamento de imagens. A utilizada neste estudo foi *denoise_wavelet*, que é uma função adaptada para receber diversos parâmetros *wavelet*, assim possibilitando trocar com facilidade para a realização de testes. (LEE, 2019)

O estudo do Oliveira (2016), onde foi utilizado a família Biorthogonal, também conhecida por bior, que como o próprio nome biorthogonal, simétrica e não ortogonal. Na Figura 16 e na Figura 17 a função 1.5 que na monografia é utilizada, no mesmo artigo faz referência sobre a família por completo na comunidade científica.

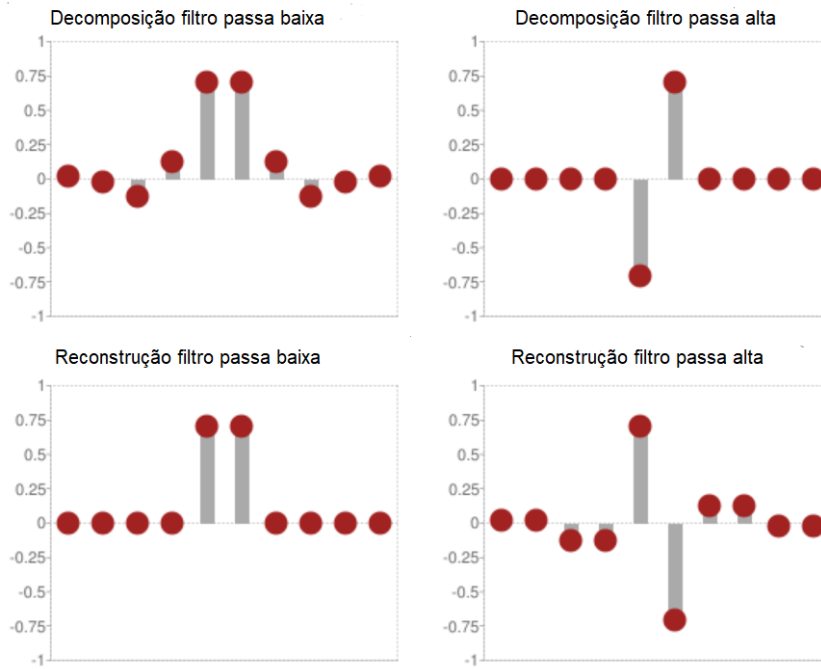
Figura 16 – Função Biorthogonal 1.5



Fonte: Wasilewski (2008)

A família Haar é a primeira definida como uma família *Wavelet* e também a mais

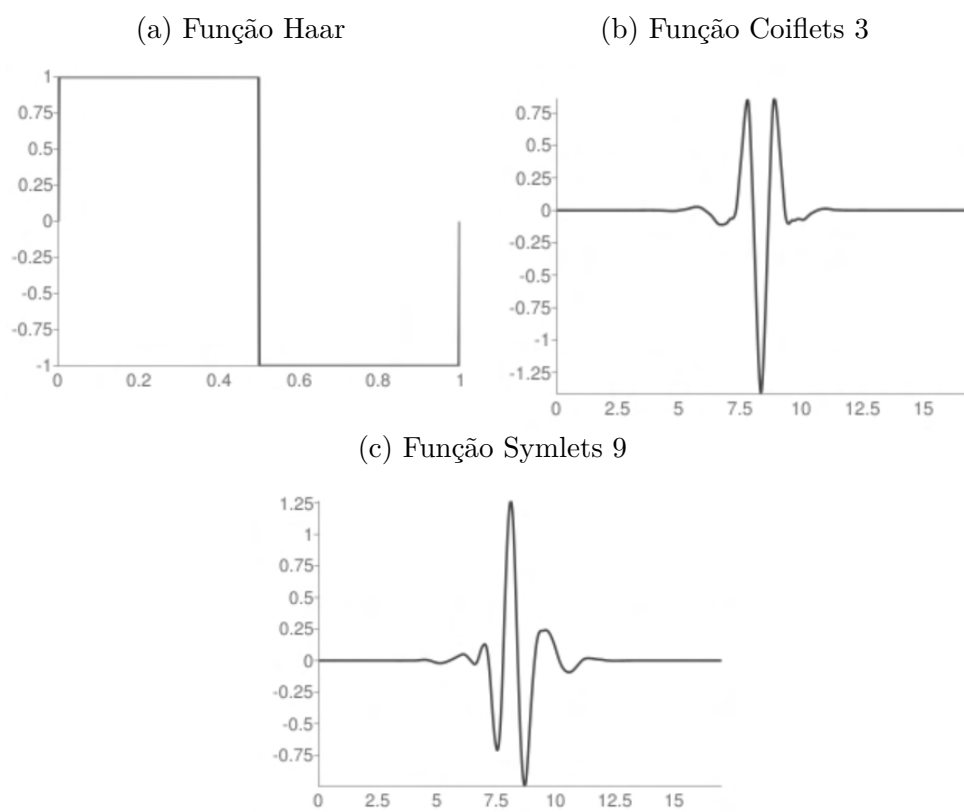
Figura 17 – Função Biorthogonal 1.5 relação de filtros



Fonte: ttWasilewski (2008)

simples, sua definição é na Figura 18a, ao defini-la como base de comparação para utilização de outras transformadas, como um grupo de controle.

No trabalho da (ARAÚJO, 2018) obteve o melhor resultado utilizando a função mães sendo a Coiflets 3 ou Coif3 que é simétrico, ortogonal e biortogonais. Seu sinal pode ser visto na Figura 18b. A família de Symlets 2 também obteve alguns bons resultados. Também para uso de controle foi utilizado a família parecida com a Biorthogonal, esta foi a Symlets 9 ou sym9 que é simétrico, ortogonal e biortogonal. Sua abstração pode ser vista na Figura 18c.

Figura 18 – Sinais *Wavelet* mães

Fonte: Wasilewski (2008)

4 RESULTADOS E DISCUSSÕES

Neste capítulo, serão apresentados os resultados aplicados e divididos por famílias, alterando os parâmetros da função, como nível de decomposição, formação de limiares e entre outros .

4.0.1 Remoção de fundo

Removendo o fundo obteve-se uma acurácia de 56,52%. e os outros parâmetros estão descritos na Tabela 2.

Tabela 2 – Resultados replicando o trabalho para 2 categorias

Métricas	Precisão	recall	F1Score
Detectados	1	0.13043	0.23077
Não Detectados	0.53488	1	0.69697

Fonte: O próprio autor.

4.0.2 Resultado com famílias Wavelet

A família Biorthogonal 1.5 é citada na literatura como a melhor para casos de mamografia de acordo com Oliveira (2016). Os resultados estão na Tabela 3 com a variação citada. A utilização de uma aplicação soft não foi possível pelo motivo de só poder ser aplicado em componentes *wavlets* que não são ortogonais.

Tabela 3 – Bayer dura Biorthogonal 1.5 por nível de decomposição

nível dedecomposição	3	6	8
Acurácia	50%	47.82%	41.30%
precisão Detectados	0.5	0.42857	0.16667
precisão Não Detectados	0.5	0.4871794872	0.45
recall Detectados	0.69565	0.13043	0.04347
recall Não Detectados	0.30435	0.82609	0.78261
F1Score Detectados	0.58182	0.2	0.06896
F1Score Não Detectados	0.37838	0.61290	0.57142

Fonte: O próprio autor.

A família Biorthogonal 3.6 é a mais conhecida por ser o exemplo utilizado na biblioteca usada Lee (2019). Esta foi a primeira família testada, ela é o principal exemplo se tratando da função utilizada.

O Haar que é a familia mais simples obteve os seguintes resultados vistos na Tabela 6.

Tabela 4 – Bayer dura Biorthogonal 3.6 por nível de decomposição

nível dedecomposição	3	6	8
Acurácia	52.17%	47.83%	50%
precisão Detectados	0.52	0.4285714286	0
precisão Não Detectados	0.52381	0.48718	0.5
recall Detectados	0.56522	0.13043	0
recall Não Detectados	0.47826	0.82609	1
F1Score Detectados	0.54167	0.2	0
F1Score Não Detectados	0.5	0.61290	0.66667

Fonte: O próprio autor.

Tabela 5 – Bayer suave Biortogonal 3.6 por nível de decomposição

nível dedecomposição	3	6	8
Acurácia	50%	47.83%	63.04%
precisão Detectados	0	0.42857	0.6
precisão Não Detectados	0.5	0.48718	0.6875
recall Detectados	0	0.1304347826	0.78261
recall Não Detectados	1	0.82609	0.47826
F1Score Detectados	0	0.2	0.67924
F1Score Não Detectados	0.66667	0.61290	0.56410

Fonte: O próprio autor.

Tabela 6 – Bayer dura Haar por nível de decomposição

nível dedecomposição	3	6	8
Acurácia	52.17%	50%	50%
precisão Detectados	0.52	0	0
precisão Não Detectados	0.5238095238	0.5	0.5
recall Detectados	0.5652173913	0	0
recall Não Detectados	0.4782608696	1	1
F1Score Detectados	0.5416666667	0	0
F1Score Não Detectados	0.5	0.66667	0.66667

Fonte: O próprio autor.

A família Symlets 2, que obteve uma SNR muito alta no trabalho da (ARAÚJO, 2018), obteve os resultados da Tabela 7. Assim como no trabalho, sendo mais satisfatório que as outras famílias citadas.

A família Symlets 9 tem o objetivo de trazer um componente *wavelet* com as mesmas características entre a Symlets 2 e a Biorthogonal 3.6, por terem resultados satisfatórios e família que tivesse características das duas poderia ter melhores resultados. Assim obtendo o seguinte resultado descrito na Tabela 8, porém não aconteceu o esperado tendo uma piora na acurácia.

Coiflet 3 é a família que teve melhores resultados em trabalhos bases, tendo então a maior SNR Tabela 9. Como o esperado, ele obteve uma acurácia maior que as famílias citadas anteriormente.

Tabela 7 – Symlets 2

Tipo	nível 3 Bayer dura	nível 8 Bayer dura	nível 5 visu suave
Acurácia	56.52%	45.65%	56.52%
precisão Detectados	0.53488	0.47059	0.47059
precisão Não Detectados	1	0.41667	0.6
recall Detectados	1	0.69565	0.73913
recall Não Detectados	0.13043	0.21739	0.39130
F1Score Detectados	0.69697	0.56140	0.62962
F1Score Não Detectados	0.23077	0.28571	0.47368

Fonte: O próprio autor.

Tabela 8 – Bayer dura Symlets 9 por nível de decomposição

nível dedecomposição	3	6	8
Acurácia	47.82%	52.17%	50%
precisão Detectados	0.48276	0.55556	0
precisão Não Detectados	0.47059	0.51351	0.5
recall Detectados	0.60869	0.3125	0
recall Não Detectados	0.34782	0.3125	1
F1Score Detectados	0.53846	0.3125	0
F1Score Não Detectados	0.4	0.63333	0.66667

Fonte: O próprio autor.

Ao se testar com o linear gerado por *Visu* obteve-se uma acurácia de 50%, por tanto não sendo relevante os demais dados.

Tabela 9 – Coif 3 Bayer

Tipo	nível 3 dura	nível 3 suave	nível 6 suave	nível 8 suave
Acurácia	56.52%	58.69%	60.86%	50%
precisão Detectados	0.8	0.57692	0.6	0
precisão Não Detectados	0.53658	0.6	0.61905	0.5
recall Detectados	0.17391	0.65217	0.65217	0
recall Não Detectados	0.95652	0.52173	0.56522	1
F1Score Detectados	0.28571	0.61224	0.625	0
F1Score Não Detectados	0.6875	0.55813	0.59091	0.66667

Fonte: O próprio autor.

4.1 Discussões

4.1.1 Métodos de avaliação dos Resultados

Ao se avaliar as métricas, a acurácia é a mais importante, mas como temos uma situação com objetivo específico, sendo este quanto menos imagens com casos forem classificados erroneamente melhor, a situação permite avaliar-se facilmente nas métricas de Detectados.

Ao se avaliar as tabelas verdade, busca-se nesse caso as com menores erros nos achados, não se atentando tanto às situações dos casos normais. Esta é a principal ferramenta avaliativa exploratória, pois como as métricas gerais levam em conta todos os dados de forma quantitativa ou quantitativamente.

Como os melhores resultados foram utilizando a família Biorthogonal 3.6, com limiarização suave, foi testada a remoção de fundo para checar se haveria melhora na acurácia. Obteve-se então uma precisão de 54.34% e as demais métricas descritas na Tabela 10.

Tabela 10 – Métricas de bayer removendo o fundo com limiarização suave e nível de decomposição 8


Métricas	Precisão	recall	F1Score
Detectados	0.52273	1	0.68657
Não Detectados	1	0.08696	0.16

Fonte: O próprio autor.

Esta piora pode ser explicada ao se observar as matrizes de confusão, pois a distribuição mostra que a melhora obtida na remoção de fundo não se adequa ao que precisa melhorar no caso que se obteve melhor precisão.

Por exemplo a matriz representada na Figura 19 mostra que as imagens com casos tiveram menor previsão, assim, ao unir com a matriz Figura 20, que precisava de maior previsão para normais poderia ter uma relevância, porém a não classificação de imagens com detecção de casos prevaleceu, piorando a acurácia de previsão. Como visto na Figura 21.

Figura 19 – Matriz de confusão removendo o fundo



Fonte: O próprio autor.

Figura 20 – Matriz de confusão, com pré processamento, nível 8, Biorthogonal 3.6 e suave





Figura 21 – Matriz de confusão com pré processamento, com nível 8 de decomposição, Biorthogonal 3.6, suave e removendo o fundo



As demais métricas formam a melhor situação pois a precisão subiu de 52.17% para 63.04% , o que significa que tiveram mais acertos que eram realmente acertos. Seu F1 Score e o recall também subiram. todas estas métricas estão definidas no subseção 2.5.1. Um treinamento com mais imagens provavelmente traria uma melhora significativa na acurácia como ocorreu no trabalho Selvathi e Poornila (2017). O código ficou disponível no Silva (2023).

5 CONCLUSÕES

Este trabalho busca checar se um pré-processamento de mamografias utilizando a remoção de ruído via transformada *Wavelet*, melhora a classificação de imagens em CNN. Esta classificação é baseada em imagens que tiveram casos de nódulos detectados ou não nas mamografias, com o objetivo de auxiliar em diagnósticos médicos.

Ao se utilizar várias famílias de transformada *Wavelet*, foi possível verificar que os resultados com a intervenção da família Biorthogonal possibilitou uma melhora significativa na acurácia do algoritmo de detecção. A Biorthogonal utiliza a variação 3.6 e o nível de decomposição 8 com o limiar sendo definido com a utilização Bayer.

Houve também o questionamento sobre a retirada do fundo das imagens que proporcionaria uma melhor detecção como dito no Selvathi e Poornila (2017). Removendo o fundo melhorou a acurácia, com o resultado sendo não tão significativo como o desejado, mas utilizando outras métricas de comparação para o objetivo que seria classificar as imagens focando em mamografias com nódulos, não se encontrou esta melhora.

Considerando que trabalhos anteriores definiram as famílias Biorthogonal e a Coiflet como as mais apropriadas para mamografias, estas obtiveram sim os melhores resultados, mas a variação não citada nos trabalhos da Biorthogonal, a variação 3.6 que se provou a melhor, e esta foi testada e utilizada como exemplo na biblioteca *denoise_wavelet*. Assim conseguindo uma precisão maior com pré processamento utilizando wavelet do que sem este.

5.1 Trabalhos futuros

Como trabalho futuro, fica o estudo de outras variações das famílias Biorthogonal e a Coiflet, pois estas parecem ter melhores resultados e precisam de um estudo aprofundado.

Outra situação seria usar o banco de dados mantido pela Universidade do sul da Flórida e realizar um treinamento mais extenso, porém necessita de uma infraestrutura melhor para alocar o código.

Uma terceira hipótese é a utilização do estudo da OLIVEIRA (2019), que ressalta os nódulos nas imagens de mamografias, e então comparar com os resultados deste trabalho.

REFERÊNCIAS

- ARAÚJO, A. C. C. P. S. Comparação de famílias wavelets para denoising de imagens mamográficas digitais. 2018. Citado 5 vezes nas páginas 23, 25, 28, 40 e 44.
- ARÊDES, B. A. R. Técnicas de Wavelet Thresholding Aplicadas no Processo de Denoising de Imagens Digitais. p. 106, 2009. Citado 3 vezes nas páginas 26, 28 e 29.
- BORGES, I. E. S. Universidade federal de uberlândia campus patos de minas graduação em engenharia eletrônica e de telecomunicações faculdade de engenharia elétrica izabela e silva borges análise do ruído impulsivo nas modulações digitais. 2017. Citado na página 26.
- CARVALHO, A. *Redes Neurais Artificiais*. 2022. Disponível em: <<https://sites.icmc.usp.br/andre/research/neural/>>. Citado na página 35.
- CHAKI, S. H. S. N.; SAEED, K. *Exploring Image Binarization Techniques*. [S.l.]: Springer, 2014. Citado na página 26.
- DAUTOV, C. P.; OZERDEM, M. S. Wavelet transform and signal denoising using wavelet method. *26th IEEE Signal Processing and Communications Applications Conference, SIU 2018*, Institute of Electrical and Electronics Engineers Inc., p. 1–4, 7 2018. Citado na página 30.
- DIAS, M. H. C. Estimação das respostas do canal real de propagação rádio-móvel nos domínios espacial e temporal análise da supressão de ruído por decomposição wavelet como técnica complementar de processamento. 4 2003. Disponível em: <https://www2.dbd.puc-rio.br/pergamum/tesesabertas/0016247_03_pretexto.pdf>. Citado 4 vezes nas páginas 28, 29, 30 e 31.
- FALCONI, L. G.; PÉREZ, M.; AGUILAR, W. G. Transfer learning in breast mammogram abnormalities classification with mobilenet and nasnet. In: *2019 International Conference on Systems, Signals and Image Processing (IWSSIP)*. [S.l.: s.n.], 2019. p. 109–114. Citado na página 34.
- INCA. In: RIO DE JANEIRO: INCA, 2021. *Deteção precoce do câncer*. Rio de Janeiro, 2021. Disponível em: <<https://www.inca.gov.br/publicacoes/livros/deteccao-precoce-do-cancer>>. Acesso em: 2021-11-09. Citado na página 25.
- INCA. *Tratamento / INCA - Instituto Nacional de Câncer*. 2021. Disponível em: <<https://www.inca.gov.br/controlado-cancer-de-mama/acoes-de-controlado/tratamento>>. Citado na página 25.
- JIANG, Y. L. et al. Computer classification of malignant and benign microcalcifications in small-field digital mammograms. *Iwdm 2000: 5th International Workshop on Digital Mammography*, p. 237–242, 2001. Disponível em: <<GotoISI>://WOS:000175527600036>. Citado 2 vezes nas páginas 36 e 37.
- LAMA, R. D. *Perceptron multicamadas*. 2016. Disponível em: <<https://commons.wikimedia.org/w/index.php?curid=53027287>>. Citado na página 33.

LEE, G. *denoise_wavelet*. 2019. Disponível em: <>. Citado 2 vezes nas páginas 39 e 43.

MALLAT, S.; HWANG, W. Singularity detection and processing with wavelets. *IEEE Transactions on Information Theory*, v. 38, n. 2, p. 617–643, 1992. Citado na página 32.

MASTOLOGIA, S. B. de. *Câncer de mama se tornou a forma mais comum da doença no mundo, alerta OMS - SBM*. 2020. Disponível em: <<https://www.sbmastologia.com.br/noticias/oms-cancer-de-mama-supera-o-de-pulmao-e-se-torna-o-mais-comum/>>. Citado na página 23.

MITCHELL, T. M. *Machine Learning*. [S.l.]: McGraw-Hill Science/Engineering/Math, 1997. Citado na página 33.

MUPPARAJU, S. et al. Comparison of various thresholding techniques of image denoising. *International Journal of Engineering Research Technology (IJERT)*, v. 2, 9 2013. Disponível em: <www.ijert.org>. Citado 2 vezes nas páginas 31 e 32.

NUBIA, D. *Nódulos benignos e malignos na mama: quais as diferenças?* - *Clínica Viver de Imagens Médicas em Brasília*. 2022. Citado na página 25.

OLIVEIRA, G. L. D. Realce de achados em mamografia. 2 2019. Citado na página 49.

OLIVEIRA, H. Proposta de Redução da Dose de Radiação na Mamografia Digital Utilizando Novos Algoritmos de Filtragem de Ruído Poisson. 2016. Citado 5 vezes nas páginas 23, 31, 32, 39 e 43.

ONCOGUIA, E. *Tipos de Câncer de Mama - Instituto Oncologia*. 2020. Disponível em: <<http://www.oncoguia.org.br/conteudo/tipos-de-cancer-de-mama/1382/34/>>. Citado na página 25.

RODRIGUES, G. et al. Automated large artery occlusion detection in stroke: A single-center validation study of an artificial intelligence algorithm. *Cerebrovascular diseases (Basel, Switzerland)*, Cerebrovasc Dis, 2021. ISSN 1421-9786. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/34710872/>>. Citado na página 33.

SALOMON, D. *Data Compression*. 2. ed. [S.l.]: Springer, 2000. Citado na página 30.

SELVATHI, D.; POORNILA, A. A. Breast cancer detection in mammogram images using deep learning technique. *Middle-East Journal of Scientific Research*, v. 25, n. 2, p. 417–426, 2017. Citado 9 vezes nas páginas 13, 23, 25, 35, 36, 37, 38, 47 e 49.

SILVA, E. P. e. 2023. Disponível em: <<https://github.com/EduardaPS/Breast-Cancer-Detection-Mammogra>>. Citado na página 47.

SOUSA, D. P. *Mamografia - o que é, indicações exame, como é realizada, preço*. 2020. Disponível em: <<https://www.saudebemestar.pt/pt/exame/imagiologia/mamografia/>>. Citado na página 26.

SUCKLING, J. *The mammographic image analysis society digital mammogram database exerpta medica*. 1994. 375–378 p. Disponível em: <<http://peipa.essex.ac.uk/info/mias.html>>. Citado 2 vezes nas páginas 13 e 37.

VIDAKOVIC, B.; MUELLER, P. Wavelats for kids a tutorial introduction. 1991. Disponível em: <<http://hjemmesider.diku.dk/~jda/biosignal/kidsA.pdf>>. Citado 2 vezes nas páginas 29 e 32.

VIEIRA, H. C. R. D. O. P. M. A. C. *TRANSFORMADA WAVELET E SUAS APLICAÇÕES NO PROCESSAMENTO DE IMAGENS*. 2010. Disponível em: <<http://helderc.github.io>>. Citado 2 vezes nas páginas 28 e 29.

WASILEWSKI, F. *Biorthogonal 1.5 wavelet (bior1.5) properties, filters and functions - Wavelet Properties Browser*. 2008. Disponível em: <<https://wavelets.pybytes.com/wavelet/bior1.5/>>. Citado 3 vezes nas páginas 39, 40 e 41.