

TÉCNICAS COMPUTACIONAIS E SUAS APLICAÇÕES EM IMAGENS MÉDICAS

André Luiz Nogueira
Hamona Novaes dos Santos

TÉCNICAS COMPUTACIONAIS E SUAS APLICAÇÕES EM IMAGENS MÉDICAS

André Luiz Nogueira
Hamona Novaes dos Santos



Ministério da Educação
**Instituto Federal de Educação, Ciência
e Tecnologia de Sergipe (IFS)**

Presidente da República

[Luiz Inácio Lula da Silva](#)

Ministro da Educação

[Camilo Sobreira de Santana](#)

Secretário da Educação Profissional e Tecnológica

[Getúlio Marques Ferreira](#)

Reitora do IFS

[Ruth Sales Gama de Andrade](#)

TÉCNICAS COMPUTACIONAIS E SUAS APLICAÇÕES EM IMAGENS MÉDICAS

André Luiz Nogueira
Hamona Novaes dos Santos



**INSTITUTO
FEDERAL**

Sergipe
Aracaju
2024

Copyright© 2024 - IFS

Todos os direitos reservados para a Editora IFS. Nenhuma parte desse livro pode ser reproduzida ou transformada em nenhuma forma e por nenhum meio mecânico, incluindo fotocópia, gravação ou qualquer sistema de armazenamento de informação, sem autorização expressa dos autores ou do IFS.

Editora-chefe

Kelly Cristina Barbosa

Projeto Gráfico da Capa

Erik Daniel dos Santos

Diagramação

Erik Daniel dos Santos

Bruna Gomes Souza

Revisor

Erika Vitória Alves Oliveira

Imagem da capa

www.freepik.com

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas do IFS

Nogueira, André Luiz.

N778t Técnicas computacionais e suas aplicações em
imagens médicas. [e-book]. / André Luiz Nogueira, Hamona
Novaes dos Santos. – Aracaju: EDIFS, 2024.

75 p.: il.

ISBN: 978-85-9591-239-7

1. Medicina. 2. Radiografia. 3. Exame de imagem. 4. Imagem
médica. I. Santos, Hamona Novaes. II. Título.

CDU 616-71

Elaborada pela Bibliotecária Kelly Cristina Barbosa CRB 5/1637

[2024]

Instituto Federal de Educação, Ciência e Tecnologia de Sergipe (IFS)

Rua Dom José Thomaz, 194 - São José, Aracaju - SE, 49015-090

TEL.: +55 (79) 3711-3146 E-mail: edifs@ifs.edu.br

Impresso no Brasil

Conselho Científico

Aline Ferreira da Silva

Ciências Sociais Aplicadas

Diego Lopes Coriolano

Engenharias

João Batista Barbosa

Ciências Agrárias

Joelson Santos Nascimento

Ciências Humanas

Juliano Silva Lima

Ciências Biológicas

Junior Leal do Prado

Multidisciplinariedades

Manoela Falcon Gallotti

Linguística, Letras e Artes

Marco Aurélio Pereira Buzinaro

Ciências Exatas e da Terra

Suplentes

Herbet Alves de Oliveira

Engenharias

José Aprígio Carneiro Neto

Multidisciplinariedades

Márcio Santos Lima

Linguística, Letras e Artes

Simone Vilela Talma

Ciências Agrárias

Tiago Cordeiro de Oliveira

Ciências Exatas e da Terra

Wanusa Campos Centurióm

Ciências Sociais Aplicadas

Editoração

Editora-chefe

Kelly Cristina Barbosa

Coordenadoria Geral da Editora IFS

Daniel Amaro de Almeida

Coordenadoria de Editoração

Célia Aparecida Santos de Araújo

Kaio Victor dos Santos Ribeiro

Coordenadoria de Recursos Editoriais

Hilton Henrique Cruz Santos Pereira

Coordenadoria de Registro e Normatização

Célia Aparecida Santos de Araújo

Kaio Victor dos Santos Ribeiro

Produção Visual

Erik Daniel dos Santos

Bruna Gomes Souza

Prefácio

A medicina moderna utiliza cada vez mais imagens para diagnosticar, tratar e monitorar doenças. Radiografias, tomografias, ressonâncias magnéticas e outras modalidades de imagem nos oferecem uma janela para o interior do corpo humano. No entanto, a interpretação dessas imagens pode ser complexa, exigindo um conhecimento especializado. É neste contexto que o processamento de imagens surge como uma ferramenta poderosa para auxiliar e aprimorar a prática médica.

Este livro se dedica à introdução do processamento de imagens no contexto da medicina, focando em três áreas fundamentais, a saber: classificação, segmentação e redução de ruído.

A classificação de imagens médicas permite que computadores identifiquem padrões e auxiliem no diagnóstico de doenças.

A segmentação de imagens médicas é essencial para isolar estruturas de interesse e quantificar a sua forma e tamanho. As técnicas de segmentação de imagens são capazes de delinear e quantificar lesões para o tratamento e acompanhamento terapêutico.

A redução de ruído em imagens médicas é crucial para melhorar a qualidade das imagens e facilitar a visualização de detalhes sutis. Imagens acometidas por ruído estão presentes em diversos tipos de imagens médicas. A redução de ruído impacta diretamente na determinação do diagnóstico do paciente, uma vez que melhora a visualização de estruturas, bem como reduz a chance de interpretações errôneas causadas por ruído.

Ao longo deste livro, o leitor encontrará uma abordagem prática e aplicada, com exemplos concretos de como o processamento de imagens está revolucionando a prática médica, de maneira a abrir caminho para uma medicina mais precisa e, consequentemente, para tratamentos mais eficazes e diagnósticos mais confiáveis.

SUMÁRIO

Lista de Abreviaturas e Siglas	10
Capítulo 1	11
1.1. História do processamento de imagem	12
1.2. Imagem digital	15
1.3. Produção de Raios X e interação com a matéria	24
1.4. Mamografia	28
1.5. Ressonância Magnética	30
1.6. Software R	33
Capítulo 2	35
2.1. Classificação de imagens	36
2.2. Aprendizado profundo	37
2.3. Aplicação	41
Capítulo 3	46
3.1. Segmentação	47
3.2. Lógica fuzzy	48
3.3. Aplicação	50
Capítulo 4	55
4.1. Redução de ruído em imagens	56
4.2. Difusão Anisotrópica	58
4.3. Aplicação	59
Referências	67

Lista de Abreviaturas e Siglas

AM – Aprendizado de Máquina

AP – Aprendizado Profundo

AT – Aprendizagem por Transferência

DDSM – Digital Database for Screening Mammography

EDP – Equação Diferencial Parcial

IA – Inteligência Artificial

IDE – Integrated Development Environment

RGB – Red, Green, Blue

RNC – Rede Neural Convolutacional

Capítulo 1

ESTE CAPÍTULO APRESENTA:

- A história do processamento de imagens
- Imagem digital
- A produção de raios X
- A mamografia
- A ressonância magnética
- O software R

1.1. **História do processamento de imagem**

Na ciência médica, um dos campos mais importantes é o processamento e análise digital de imagens. Este fato se deve aos rápidos avanços nos métodos de diagnóstico assistido por computador e terapias guiadas por imagens. Por exemplo, o processamento digital de imagens é primordial para o diagnóstico, detecção precoce e a análise das respostas ao tratamento do câncer (SILVA, PATROCÍNIO E SCHIABEL, 2019).

A história do processamento de imagem está intimamente ligada ao desenvolvimento do computador digital. Desse modo, embora o conceito de computador remonte à invenção do ábaco na Ásia Menor, há mais de 5 mil anos, o computador digital moderno surge apenas na década de 1940, a partir dos estudos de Jhon Von Neumann. Contudo, somente no início da década de 1960, foram desenvolvidas as primeiras máquinas poderosas o suficiente para realizar tarefas de processamento de imagem significativas (GONZALES, 2010).

No ano de 1964, teve início o emprego de técnicas computacionais para melhoramento de imagens da lua, produzidas por uma sonda espacial. No final da década de 1960 e início de 1970, estas técnicas também passaram

a ser aplicadas em imagens médicas, devido principalmente à invenção da tomografia computadorizada no início da década de 1970 (GONZALES, 2010).

A área do processamento de imagem cresceu rapidamente e, atualmente, além da aplicação na medicina e nos programas espaciais, ela está presente em diversos campos como:

- Indústria;
- Geografia;
- História;
- Arqueologia;
- Geologia;
- Física e áreas afins;
- Engenharias;
- Comunicação;
- Segurança pública e defesa.

Por outro lado, as técnicas de processamento de imagens são (CHITRADEVI E SRIMATHI, 2014):

- Pré-processamento: envolve um conjunto de métodos usados para melhorar a aparência visual da imagem ou para convertê-la em um formato mais adequado para a interpretação humana;
- Realce: tem por objetivo acentuar certas características da imagem para análise subsequente ou visualização;
- Segmentação: é um dos principais problemas no processamento de imagens, ela divide a imagem em suas partes/objetos constituintes;
- Extração de características: sua finalidade é extrair características da imagem para posterior classificação;
- Classificação: consiste em conferir um rótulo aos objetos da imagem, baseado nas características das mesmas.

Ao retomar a aplicação do processamento de imagem na medicina, a maioria das imagens médicas digitais não é apropriada para a visualização direta. Portanto, é necessário o pré-processamento da imagem para correção ou realce adequado, de forma a melhorar, por exemplo, o contraste, *pixels* defeituosos e a redução de ruídos (SILVA, PATROCÍNIO E SCHIABEL, 2019).

As técnicas de processamento de imagem podem ser aplicadas em diversos exames diagnósticos e terapias guiadas por imagem, tais como:

- Radiografia;
- Mamografia;
- Tomografia Computadorizada;
- Ultrassonografia;
- Ressonância magnética;
- Angiografia;
- Laparoscopia;
- Cintilografia.

O processo de aquisição das imagens estudadas neste livro será abordado nos tópicos seguintes.

1.2. Imagem digital

Para a compreensão do texto sobre imagem digital, vale a pena relembrar alguns conceitos sobre luz. A luz é uma radiação eletromagnética, composta por fótons, ou seja, “pacotes de energia”, que como tal apresenta propriedades como polarização, reflexão e interferência. É percebida pelos órgãos visuais e se situa no espectro eletromagnético, entre a radiação infravermelha e ultravioleta, como pode ser visto na figura 1 (HALLIDAY IV, 2016).





Figura 1 - Espectro eletromagnético




Fonte: (WIKIMEDIA COMMONS, 2024).

O espectro eletromagnético mostra que quanto maior o comprimento de onda da radiação eletromagnética, menor será a sua frequência e vice-versa. A luz visível ocupa uma pequena faixa do espectro eletromagnético,

cujas cores estão associadas às frequências. Os tons de vermelho são encontrados em frequências mais baixas, já os tons de azul estão associados às frequências mais altas. Com estas informações, é possível agora introduzir o conteúdo de imagem digital.

Uma imagem digital é definida matematicamente por uma função bidimensional, $f(x,y)$ em que x e y são coordenadas espaciais e a amplitude em qualquer par de coordenadas (x,y) de f é chamada intensidade (GONZALES, 2010).

Figura 2 - a) Imagem mamográfica do *Phantom* Mama 300. b) Demonstração de como é formada a imagem a partir dos *pixels*.



Fonte: (Próprio autor).

A figura 2b mostra uma imagem dividida em pequenos quadrados, em que cada quadrado representa um dos *pixels* que forma a imagem (figura 2a). *Pixel* é o termo utilizado para denominar os elementos que compõem a imagem, tendo cada pixel uma localização específica.

A imagem digital pode ser colorida ou monocromática. Para imagens coloridas, um dos modelos mais comuns para a intensidade ou escala de cores é o RGB (*red, green, blue*), no qual cada cor está associada a um intervalo de frequência, como foi visto na figura 1. Além

disso, em imagens monocromáticas esta intensidade é conhecida como níveis de cinza (L), estabelecendo um intervalo ($L_{\min}, L_{\max}$) em que seus valores são finitos e inteiros. $L_{\min}$ é associado ao *pixel* preto, $L_{\max}$ ao *pixel* branco e os valores entre os dois limites do intervalo são associados aos tons de cinza, conforme pode ser visualizado na figura 3 (FILHO E NETO, 1999).

Figura 3 - Escala de cinza



Fonte: (Próprio autor).

Para transformar uma cena real em uma imagem digital são necessárias duas etapas relevantes. A primeira é a aquisição da imagem e a segunda é a digitalização da imagem, sendo feita a partir da discretização em amplitude (quantização) e espacial (amostragem) (DÓCUSSE, 2008).


Em síntese, a amostragem basicamente transforma a imagem analógica em uma matriz R por S pontos, sendo cada ponto um *pixel*, como foi visto na figura 2b e visualizada no exemplo da matriz (1).

$$f(x, y) = \begin{pmatrix} f(0,0) & f(0,1) & \dots & f(0, S-1) \\ f(1,0) & f(1,1) & \dots & f(1, S-1) \\ \vdots & \vdots & \vdots & \vdots \\ f(R-1,0) & f(R-1,1) & \dots & f(R-1, S-1) \end{pmatrix} \quad (1)$$

A quantização discretiza o brilho da cena, ou seja, faz com que cada um destes *pixels* assumam valores inteiros na faixa de 0 a n, observando que quanto maior o valor de n, maior a quantidade de níveis de cinza presentes na imagem obtida (FILHO E NETO, 1999).

O processo de digitalização da imagem está diretamente relacionado à resolução da imagem digital, uma vez que a resolução espacial da imagem é dada pelo número de *pixels* presentes na matriz que a compõe. Quanto maior o número de *pixels*, maior será a resolução, o que acarreta em uma grande ocupação do espaço em memória do computador, porém, melhores serão os detalhes da imagem, conforme mostram as figuras 4 e 5 da base DDSM (HEATH *et al.*, 1998, 2001).

Figura 4 - Imagem com resolução espacial 3128x1583



Fonte: (HEATH *et al.*, 1998, 2001)

Figura 5 - Imagem com resolução espacial 31x15
(alterada a partir da imagem anterior)




Fonte: (HEATH *et al.*, 1998, 2001)

Já a resolução de intensidade, refere-se aos níveis de cinza, sendo que quanto maior a resolução de intensidade, mais tons de cinza estarão presentes, o que resulta em uma boa qualidade da imagem, visto que são identificados mais detalhes, todavia, exige um maior espaço na memória do computador, assim como maior tempo para o processamento desta imagem (GONZALES, 2002; DÓCUSSE, 2008). Nesse sentido, as figuras 6 e 7 exemplificam a importância da resolução de intensidade na qualidade da imagem, de maneira que

a imagem da figura 6 foi obtida da plataforma Kaggle (Chowdhury *et al.*, 2020; Rahman *et al.*, 2021) e a imagem da figura 7 foi gerada processando a imagem da figura 6.

Figura 6 - Resolução especial 299x299 e 256 níveis de cinza



Fonte: (Chowdhury *et al.*, 2020; Rahman *et al.*, 2021)

Figura 7 - Resolução especial 299x299 e 2 níveis de cinza



Fonte: (segmentada a partir da imagem anterior)

A Tabela 1 relaciona a resolução espacial e de intensidade da imagem com o espaço necessário para seu armazenamento.

Tabela 1 - Número de bits necessários para armazenar uma imagem.

Resolução (Pixels)	Tons de cinza		
	4 tons	8 tons	16 tons
16 × 16	32 bits	48 bits	64 bits
32 × 32	50 bits	75 bits	100 bits
64 × 64	72 bits	108 bits	144 bits

Como já foi citado, a imagem digitalizada é representada por uma matriz, logo, os *pixels* podem se relacionar principalmente através de dois métodos: a vizinhança e a conectividade. A vizinhança pode ocorrer de três formas (GONZALEZ, 2002; THOMÉ, 2024):

- a vizinhança - 4 de S, em que S é o *pixel* em estudo, fazendo fronteira com 4 *pixels* através das arestas, conforme pode ser observado na figura 8a;
- a vizinhança diagonal, que como o próprio nome sugere, consistem nos quatros *pixels* ligados a S pela diagonal, forma visualizada na figura 8b;
- a vizinhança - 8, formada por todos os pixels em torno de S, como mostra a figura 8c.

===== **Figura 8** - a) Vizinhança - 4, b) vizinhança diagonal, c) vizinhança - 8 =====




===== **Fonte:** (Próprio autor). =====

A conectividade é extremamente importante para a determinação de bordas de uma imagem, pois depende diretamente da similaridade dos níveis de cinza entre os pixels, de modo que podem ocorrer em três situações distintas, sendo elas (THOMÉ, 2024):

- conectividade - 4: Caracteriza-se quando dois *pixels*, S e R, apresentam vizinhança - 4 e valores de tons de cinza similares, como exemplificado na figura 9a, considerando uma imagem apenas com dois níveis de cinza;

- conectividade – 8: Acontece quando dois *pixels*, *S* e *R*, estão em vizinhança – 8 e valores de tons de cinza semelhantes, como mostra o exemplo da figura 9b.
- conectividade mista: Configura-se somente quando os *pixels* *S* e *R*, que estão em vizinhança – 4 ou diagonal, apresentam valores de tons de cinza similares e obtêm uma intersecção entre as vizinhanças – 4 de *S* e *R* vazia, como pode ser visto no exemplo da figura 9c.

== **Figura 9** - a) Conectividade – 4, b) Conectividade – 8, c) Conectividade mista ==



===== **Fonte:** (Próprio autor). =====


Com isso, considerando os conceitos abordados neste breve estudo sobre fundamentos da imagem digital, o texto continuará falando sobre algumas técnicas utilizadas para aquisição destas imagens.

1.3. **Produção de Raios X e interação com a matéria**

Os raios X são ondas eletromagnéticas de pequeno comprimento de onda e alta frequência, que foram descobertos em 1895 por Wilhelm Roentgen. Atualmente, estes são muito aplicados em diversas áreas, destacando-se a indústria e medicina.

A produção de raios X em tubos de raios X ocorre basicamente quando um filamento é aquecido, emitindo elétrons que são acelerados através da aplicação de uma diferença de potencial entre seus eletrodos, o cátodo e o ânodo. Estes elétrons desaceleram bruscamente ao colidirem em um alvo, normalmente de tungstênio ou molibdênio, perdendo energia através da emissão de raios X (OKUNO, 2010). O esquema deste processo pode ser visto na figura 10.

Figura 10 - Esquema de um tubo de raios X



Fonte: (ADAPTADO DE WIKIMEDIA COMMONS, 2024).


A intensidade e a energia do feixe de raios X gerados dependem da tensão e da corrente aplicadas ao tubo, assim, quanto maior a tensão aplicada, maior será a energia, e quanto maior a corrente aplicada maior será a intensidade do feixe (EISBERG, 1994).

Os processos fundamentais envolvidos na produção de raios X são o *Bremsstrahlung* ou radiação de freamento e o raio X característico. A radiação de freamento ocorre quando um elétron é desacelerado devido à interação coulombiana com o núcleo de um dos átomos que forma o material que compõe o alvo, emitindo assim raios X. Já os raios X característicos advêm de parte da energia transferida do elétron incidente para um átomo do material que forma o alvo, de forma a remover um elétron de camada mais interna, normalmente a K, deixando um “buraco” nesta camada energética. Dito isto, como o átomo se encontra ionizado, e para que ele se estabilize, um elétron

de camada mais externa decai e ocupa o buraco deixado pelo elétron removido, de maneira que o excesso de energia deste elétron que decaiu é emitido em forma de raios X característicos (OKUNO, 2010).

Os raios X podem interagir com a matéria através principalmente de três fenômenos denominados efeito fotoelétrico, efeito Compton e produção de pares. O efeito fotoelétrico é predominante para interações que envolvem baixa energia do feixe de raios X e alvo composto de elementos químicos de alto número atômico. Quanto às energias intermediárias, o efeito Compton passa a ser predominante; já para energias acima de alguns MeV a produção de pares é a principal contribuição para as interações dos fótons (EISBERG, 1994). A figura 11 apresenta a variação da participação de cada um destes processos levando em consideração o número atômico (Z) e a energia dos fótons.


Figura 11 - Predominância dos processos de interação da radiação com a matéria considerando o número atômico e a energia. Valores obtidos a partir da base de dados XCOM



Fonte: (NIST, 2010)

Nesse aspecto, como a faixa de energia envolvida no radiodiagnóstico está entre 20 – 125 kVp, apenas dois dos processos citados são importantes para este estudo, sendo o efeito fotoelétrico e o efeito Compton. O efeito fotoelétrico ocorre quando um fóton é absorvido por um átomo, provocando assim a liberação de um elétron fortemente ligado ao núcleo com energia igual à energia do fóton absorvido menos a energia de ligação deste elétron com o átomo (EISBERG, 1994), em conformidade com o que é demonstrado na figura 12a. No tocante ao efeito Compton, o fóton interage com um elétron orbital de baixa energia de ligação e transfere parte da sua energia, ejetando-o do átomo, já o fóton sofre um desvio na sua trajetória, processo este demonstrado na figura 12b.

Figura 12 - a) Demonstração do Efeito fotoelétrico. b) Demonstração do Efeito Compton.



Fonte: (TAUHATA et al, 2003).

1.4. Mamografia

A mamografia é a técnica mais eficaz na detecção do câncer de mama em um estágio inicial. É um exame que faz uso de um tubo de raios X no qual se aplica baixo kV (quilovoltagem) e alto mAs (miliamperagem), ou seja, utiliza-se um feixe com baixa energia e alta intensidade, com o objetivo de aumentar o contraste na imagem final, visto que as estruturas que compõem a mama apresentam densidades muito parecidas (OKUNO, 2010).

A mamografia é a técnica mais eficaz na detecção do câncer de mama em um estágio inicial. É um exame que faz uso de um tubo de raios X no qual se aplica baixo kV (quilovoltagem) e alto mAs (miliamperagem), ou seja, utiliza-se um feixe com baixa energia e alta intensidade, com o objetivo de aumentar o contraste na imagem final, visto que as estruturas que compõem a mama apresentam densidades muito parecidas (OKUNO, 2010).

O mamógrafo utiliza uma bandeja de compressão no intuito de imobilizar e reduzir a espessura da mama. O ponto focal deve ser pequeno, uma vez que as microestruturas presentes na mama, como as microcalcificações, apresentam dimensões muito pequenas de cerca de 0,03 mm. Outros componentes de extrema importância presentes no mamógrafo são os colimadores, restritores e os filtros. Os dois primeiros têm a função de direcionar e barrar a radiação

desnecessária do feixe de raios X gerado, evitando que outros órgãos do paciente sejam irradiados. Os filtros, por outro lado, impedem que os fótons de baixa energia, que são irrelevantes para o diagnóstico, atinjam o paciente, aumentando a dose recebida pelo mesmo (ROSA, 2005). O mamógrafo, desse modo, apresenta ainda uma grade, que é confeccionada de material com alto número atômico, tendo como função absorver a radiação espalhada, evitando que o contraste da imagem seja afetado. A figura 13 apresenta um mamógrafo.

Figura 13 - Mamógrafo



Fonte: (FREEPICK, 2024).

Na mamografia digital, a obtenção da imagem é feita por uma placa de semicondutores, como o fósforo. Esta placa de fósforo de iodeto de cézio é ligada a uma matriz de fotodiodos com um substrato

de silicone amorfo. Em linhas gerais, cada elemento diodo sensível à luz é conectado por um transistor de filme fino a uma linha controle e uma linha de dados, de modo que cada carga desenvolvida em um diodo – devido à emissão de luz do fósforo – possa ser lida e digitalizada (FREITAL *et al*, 2006).

1.5. **Ressonância** **Magnética**

A ressonância magnética é uma propriedade física apresentada por núcleos de determinados elementos que, quando excitados por ondas de rádio em determinada frequência e expostos a um forte campo magnético, emitem sinal de rádio, que pode ser captado por uma antena e transformado em imagem (HAGE E IWASAKI, 2009).

Diversos núcleos podem ser utilizados para obtenção de imagens por ressonância magnética, entretanto, o mais comum é o de hidrogênio, por ser este o átomo mais abundante no corpo humano e possuir alta sensibilidade ao fenômeno da ressonância magnética. O sinal que pode ser obtido do hidrogênio é superior a 1000 vezes em relação

a qualquer outro elemento presente nos tecidos do corpo, além de que o núcleo do hidrogênio consiste em um único próton. Prótons e nêutrons apresentam uma propriedade conhecida como *spin* ou momento angular, sendo este caracterizado por uma rotação similar à rotação da Terra sob o seu próprio eixo. O próton possui ainda carga positiva e um momento magnético, sendo, portanto, um dipolo magnético (HAGE E IWASAKI, 2009; MARCHIORI E SANTOS, 2015; DAFFNER, 2013).

O dipolo magnético não somente produz um campo magnético, como também responde à presença de qualquer campo magnético de outras fontes (HAGE E IWASAKI, 2009).

Os átomos de hidrogênio têm orientação aleatória no corpo humano. Quando expostos a um campo magnético intenso, os prótons se alinham ao eixo deste campo. Quando cessada a excitação, os prótons retornam à posição de equilíbrio liberando energia, que é captada e emite um sinal ao equipamento de ressonância magnética, formando a imagem (MARCHIORI E SANTOS, 2015).

A corrente elétrica que passa por uma bobina de fios metálicos, imersas em hélio líquido a temperaturas próximas do zero absoluto, gera o campo magnético que forma o grande imã, sendo este o aparelho de ressonância magnética (Figura 14). Assim, tal aparelho aplica um pulso de radiofrequência na frequência de precessão do hidrogênio, dando energia ao próton que desvia do eixo do campo magnético. Por sua vez, o próton retorna ao estado inicial quando o pulso de radiofrequência termina, liberando a energia que é captada pela antena e transmitida aos computadores (MARCHIORI E SANTOS, 2015).

Figura 14 - Aparelho de Ressonância magnética.




Fonte: (FREEPICK, 2024).

A intensidade do sinal depende de vários fatores, como a quantidade de hidrogênio. Nesse sentido, quanto maior a quantidade de hidrogênio mais intenso será o sinal de ressonância magnética, como ocorre com a gordura e cartilagem, que exibem alta intensidade de sinal, o que se traduz em uma imagem de coloração branca. Já os tecidos como osso cortical e pulmões cheios de ar, apresentam baixa concentração de hidrogênio, emitindo pouco ou nenhum sinal de ressonância magnética, o que resulta em imagens de coloração negra (DAFFNER, 2013).

1.6. **Software R**

O R (R CORE TEAM, 2022) é uma linguagem de programação e um ambiente de trabalho, ou seja, após a execução de comandos, os resultados são exibidos como texto ou gráficos. Além disso, o R é uma ferramenta poderosa e completa, com milhares de pacotes nas mais diversas áreas (BEELEY, 2016; CARLSON, 2017). O interesse em aprender o R se difunde por diversas profissões, tais como: professores, estatísticos, engenheiros, administradores, biólogos, químicos, matemáticos, geógrafos, programadores, contadores, sociólogos, jornalistas, psicólogos, cientistas políticos, médicos, enfermeiros, assistentes sociais, etc (ALCOFORADO, 2021). O Rstudio (RSTUDIO TEAM, 2021) é uma IDE (*Integrated Development Environment*) do R utilizada por milhões de pessoas, de maneira que todos os códigos apresentados neste livro foram escritos usando o Rstudio versão 4.3.1. Dito isto, ao clicar no ícone do Rstudio, será aberta uma janela, como mostra a figura 15.

Figura 15 - Janela do Rstudio



Fonte: (Próprio autor).

Capítulo 2

ESTE CAPÍTULO:

- Introduz conceitos da classificação de dados
- Aborda as principais características e áreas do aprendizado profundo

2.1. Classificação de imagens

A classificação geralmente é o último passo do processo de diagnóstico, e envolve dividir objetos em uma imagem, em classes (DOUGHERTY, 2009). A classificação de imagens é uma etapa essencial na análise de imagens médicas (YANG et al., 2023).

A análise de imagens médicas é composta das seguintes etapas:

- extração e representação de características;
- seleção de características que serão usadas para classificação;
- classificação das imagens.

O objetivo de um sistema de classificação é mapear dados de entrada (por exemplo, imagens) em uma variável de saída (MIRANDA, ARYUNI E IRWANSYAH, 2016). A variável de saída pode ser, por exemplo, um rótulo indicando se a imagem correspondente é, ou não, de uma pessoa com determinada doença.

A classificação de imagens é um grande desafio, haja vista que avaliar e diagnosticar uma doença específica com o uso de imagens médicas não é uma tarefa fácil (MIRANDA, ARYUNI E IRWANSYAH, 2016).

Entre os métodos de classificação de imagens, destacam-se:

- métodos estatísticos;
- sistemas baseados em regras;
- redes neurais;
- máquinas de vetores suporte.

As redes neurais surgiram como uma importante ferramenta para a classificação, de forma que entre as principais vantagens de sua utilização estão (SMITHA, SHAJI L. E MINI, 2011):

- as redes neurais são métodos auto adaptativos, elas se ajustam aos dados;
- as redes neurais podem aproximar qualquer função;
- as redes neurais são modelos não-lineares, o que permite a modelagem de aplicações complexas.

2.2. **Aprendizado Profundo**

Nos últimos anos, a inteligência artificial (IA) tem sido objeto de intensa campanha publicitária pela mídia. A IA nasceu na década de 1950, e é um campo que abrange o aprendizado de máquina (AM), além de envolver outras abordagens. O AM teve grande impulso na década de 1990, tornando-se a subárea mais popular e bem-sucedida da IA, impulsionada por hardwares mais rápidos, bem como conjuntos de dados maiores (CHOLLET E ALLAIRE, 2018).

Na programação clássica são inseridos dados e regras, de modo que os dados são processados de acordo com as regras e são obtidas as respostas. Por

outro lado, no aprendizado de máquina, são inseridos os dados e as respostas esperadas, e obtêm-se as regras. Ademais, ao contrário da programação clássica, no AM os sistemas são treinados, de maneira que o treinamento permite ao sistema extrair regras a partir dos dados e das respostas. O aprendizado profundo (AP) é uma subárea do AM, isto é, através de camadas sucessivas o AP extrai características dos dados de entrada e essas camadas estão associadas ao modelo da rede. Recentemente, o AP tem alcançado sucesso em diversos campos, como visão computacional e análise de imagens (MAIER et al., 2019). O AP, deve-se ressaltar, foi desenvolvido a partir de redes neurais artificiais, cuja pesquisa teve início na década de 1940, com o trabalho de MCCULLOCH e PITTS (1943).

Nesse sentido, o AP proporcionou avanços notáveis em áreas que tradicionalmente representavam obstáculos para o aprendizado de máquina (CHOLLET E ALLAIRE, 2018), a saber:

- classificação de imagem;
- reconhecimento de fala;
- transcrição de manuscrito;
- tradução automática;
- conversão de texto em fala;
- condução autônoma;
- capacidade de responder perguntas em linguagem natural.

Nas seguintes situações, o AP pode ser utilizado (ALOM, 2019):

- ausência de especialista humano;
- os especialistas incapazes de aplicar seus conhecimentos;
- na solução de problemas que mudam ao longo do tempo;
- o problema é muito vasto para as capacidades humanas.

Redes neurais profundas, como o próprio nome indica, fazem uso de algoritmos de AP e são compostas por camadas interligadas que operam como um sistema para mapear entradas em suas respectivas saídas. Cada camada atua como uma etapa de transformação, processando a entrada e gerando uma saída. Tais transformações são realizadas por meio de cálculos matemáticos, guiados por um conjunto de parâmetros. Desse modo, o objetivo do aprendizado em redes neurais profundas consiste em determinar os valores ideais para os parâmetros de todas as camadas. Isto permite, portanto, que a rede mapeie com precisão as entradas em suas saídas (WANI et al., 2020).

Uma rede neural artificial é uma combinação de neurônios, de suas conexões e do algoritmo usado no treinamento. Além disso, a rede neural possui dois estágios de processamento, a saber: aprendizado e aplicação de rede.

No aprendizado, o ajuste dos pesos ocorre em resposta aos dados (conjunto de treinamento) apresentados à rede. Na aplicação da rede, tem-se a forma como a rede responde aos dados sem que haja alteração nos pesos.

A compreensão e representação dos dados são importantes no desenvolvimento de sistemas inteligentes baseados em AP, os dados podem estar em vários formatos e, entre eles, destacam-se (SARKER, 2021):

- sequencial é um tipo em que a ordem importa, ou seja, um conjunto de sequências como, por exemplo, fragmentos de áudio e séries temporais;

- imagem é uma matriz numérica, organizada em um arranjo de linhas e colunas;
- tabulado é composto de linhas e colunas, como uma tabela de um banco de dados, cada coluna deve ter um nome e só pode conter dados do tipo definido.

Não obstante, entre as técnicas de aprendizado profundo para o diagnóstico do coronavírus, as redes neurais convolucionais (RNC) têm se destacado (ASLANI E JACOB, 2023).

Na área médica, a RNC alcançou performance de especialistas em várias áreas. Esta rede neural artificial pode ajudar não apenas pesquisadores que trabalham com imagens médicas, mas também os radiologistas clínicos, podendo influenciar na sua prática em radiologia no futuro (Yamashita, 2018).

Dito isto, existem três técnicas relevantes que empregam RNC com sucesso na classificação de imagens médicas: treinar RNC do zero, utilizar RNC pré-treinadas (aprendizagem por transferência (AT)) e realizar pré-treinamento com ajuste fino. A presente aplicação do capítulo irá utilizar RNC pré-treinadas (Shin et al., 2016).

AAT tem como objetivo a generalização de novas tarefas. Trata-se, em síntese, de uma técnica usada para transferir o conhecimento apresentado nas tarefas de origem para as novas tarefas. A AT tem potencial para melhorar a taxa de convergência e generalização, que acarretará um desempenho superior em testes, quando comparada com RNC sem AT (SAMALA, et al., 2017).

2.3. Aplicação

A identificação de uma pneumonia causada por COVID-19 e uma causada por outra doença não é uma tarefa fácil, demanda bastante experiência no campo da radiologia. Deve-se frisar, quanto a isto, que o desenvolvimento de programas baseados em processamento de imagens e o aprendizado profundo podem ser uma ferramenta útil para facilitar a luta dos profissionais de saúde contra a COVID-19 (BUKHARI, 2020).

A aplicação desenvolvida utiliza o modelo VGG19 (SIMONYAN E ZISSERMAN, 2014), uma RNC profunda, que é capaz de identificar se a imagem é de um paciente:

- normal;
- com covid;
- com pneumonia.

O código foi desenvolvido utilizando a linguagem R (TEAM, 2023) , de forma que os pacotes utilizados foram: TensorFlow (ALLAIRE E TANG, 2023) e Keras (ALLAIRE E CHOLLET, 2023), que facilitam a construção, o treinamento e o teste das RNC.

As 1200 imagens (299x299x3) do Banco de dados de radiografia de tórax (Chowdhury et al. 2020; Rahman et al., 2021) estão divididas da seguinte forma:

- 400 imagens de radiografia afetadas por COVID-19;
- 400 imagens de radiografia normais;
- 400 imagens de radiografia afetadas por pneumonia viral.

As figuras 16, 17 e 18 mostram exemplos de imagens da base de dados.

Figura 16 - Imagens da base de dados



Fonte: Chowdhury *et al.* 2020; Rahman *et al.*, 2021

Figura 17 - Imagens da base de dados



Fonte: Chowdhury *et al.* 2020; Rahman *et al.*, 2021

Figura 18 - Imagens da base de dados



Fonte: Chowdhury *et al.* 2020; Rahman *et al.*, 2021

Quanto ao treinamento da rede, foram utilizadas 960 imagens, sendo 192 usadas para validação e 240 para o teste. A avaliação de desempenho foi realizada calculando a acurácia e o resultado obtido foi 94,58% de acerto. Segue abaixo o código implementado.

```
.  
#carregando as imagens do conjunto de treinamento  
treino <- image_dataset_from_directory(caminho, validation_  
split = 0.2,  
  
subset = "training",  
seed = 1337,  
image_size = c(299,299),  
batch_size = 32)  
  
#carregando as imagens do conjunto de validação  
valida <- image_dataset_from_directory(caminho, validation_  
split = 0.2,  
  
subset = "validation",  
seed = 1337,  
image_size = c(299,299),  
batch_size = 32)  
  
# carregando as imagens do conjunto de teste  
teste <- image_dataset_from_directory(caminho,  
image_size = c(299,299),  
batch_size = 32)  
  
# modelo pré-treinado que irá compor a rede neural  
modelo_base <- application_vgg19(  
weights = 'imagenet',
```

```

    include_top = FALSE,
    pooling = 'avg'
)

# congelando o modelo
modelo_base$trainable <- FALSE

# construindo o novo modelo a partir do modelo pré-treinado
modelo <- keras_model_sequential() %>%
  layer_resizing(224,224) %>%
  modelo_base() %>%
  layer_dense(512,activation = "relu") %>%
  layer_dense(3,activation = "softmax")

#compilando o modelo
modelo %>% compile(
  optimizer = 'adam',
  loss = 'sparse_categorical_crossentropy',
  metrics = c('accuracy')
  #metrics = c('metric_recall()')
)

#treinando o modelo
modelo %>% fit(treino, epochs = 60, verbose = 2,
              validation_data=valida)

#avaliacao do modelo
score <- modelo %>% evaluate(teste, verbose = 2)

```

Capítulo 3

ESTE CAPÍTULO TRAZ:

- Uma breve descrição de segmentação de imagens
- Apresenta conceitos e aplicações da lógica *fuzzy*
- Aplicação de um método de segmentação baseado em lógica *fuzzy*

3.1. Segmentação

Há um aumento de demanda para segmentação de imagens, com o desenvolvimento da tecnologia de informação. A segmentação é um problema básico no processamento de imagens e, recentemente, princípios matemáticos têm sido aplicados à segmentação (YUHENG E HAO, 2017). Com a ajuda da segmentação de imagens, médicos são capazes de analisar imagens com precisão e rapidez, consequentemente reduzindo a taxa de diagnósticos incorretos.

A segmentação divide a imagem em regiões de acordo com diferentes características, tais como textura, nível de cinza, brilho, etc. As regiões devem estar relacionadas com objetos ou características de interesse, sendo dessa forma úteis para a análise e interpretação de imagens. Ademais, diferentes métodos de computação *fuzzy* e *crisp* são usados para segmentação de imagens médicas (SINHA, TUTEJA E SAXENA, 2020). Atualmente, a segmentação de imagens enfrenta desafios, entre eles destacam-se:

- não é possível segmentar diferentes tipos de imagens usando o mesmo método;
- os métodos tradicionais não são eficientes na preservação dos detalhes da imagem.

Alguns métodos de segmentação têm sido melhorados, novas teorias matemáticas têm sido usadas na segmentação, inclusive combinando técnicas de segmentação diferentes (HORE E ZIOU, 2010).

A metodologia convencional se baseia em princípios como precisão, certeza e inflexibilidade. Por outro lado, a computação *fuzzy* é uma abordagem moderna baseada na ideia de aproximação, incerteza e flexibilidade (SINHA, TUTEJA E SAXENA, 2020). A segmentação é necessária na área médica, tendo em vista que impacta no planejamento do tratamento, assim como contribui para a localização, por exemplo, do tumor cerebral, além da detecção do câncer de mama (DONG et al., 2014).

3.2. Lógica *fuzzy*

Na lógica clássica, um dado elemento x pode ou não pertencer a um conjunto A . Se o elemento x pertence ao conjunto A , a função de pertinência (μ_A) associada assume o valor 1 ($\mu_A(x)=1$), caso o elemento não pertença ao conjunto A , a função de pertinência assume o valor 0 ($\mu_A(x)=0$). Assim, cada elemento, na teoria clássica de conjuntos, pode pertencer ou não ao conjunto, de maneira que a função de pertinência assume apenas dois valores 0 ou 1.

Na década de 1960, Zadeh (1965) apresenta a teoria de conjuntos *fuzzy*, com base em princípios de incerteza, ambiguidade e imprecisão. Tal autor sugere que no mundo real um elemento pode pertencer parcialmente a um conjunto, nesse caso, a função de pertinência pode assumir valores no intervalo $[0,1]$. Os conjuntos *fuzzy* têm sido muito utilizados em áreas como processamento de imagens, reconhecimento de padrões, sistemas de suporte de decisão, etc (CHAIRA E RAY, 2017).

Além disso, a lógica *fuzzy* compreende um dos três pilares da inteligência artificial (IA), os outros são redes neurais e algoritmos genéticos. A lógica *fuzzy* é uma generalização da lógica clássica (crisp) e fornece mecanismos de aproximação e inferência. Em decorrência de sua eficácia, as técnicas de IA, como lógica *fuzzy*, desempenham um papel relevante na medicina. Estes métodos possibilitam não somente diagnóstico eficiente, mas também rápido (VLAMOU E PAPADOPOULOS, 2019).

Nessa perspectiva, entre as aplicações da lógica *fuzzy* no processamento de imagem, destacam-se (KAUR E CHAIRA, 2021):

- realce de imagens;
- segmentação de imagens;
- detecção de borda;
- recuperação de imagem por conteúdo.

3.3. Aplicação

A segmentação de imagens tem um papel de destaque no processamento de imagens. Por outro lado, a qualidade da imagem médica impacta diretamente no diagnóstico e tratamento. Desse modo, sobretudo na radioterapia, a imagem é parte essencial da rotina terapêutica, pois permite que apenas a região do alvo do tratamento receba radiação, além de auxiliar no cálculo da dose de radiação. Assim, a segmentação é muito importante para o tratamento do paciente, visto que permite determinar o alvo do tratamento (RAMESH, 2021).

A aplicação que se segue utiliza um método de segmentação de imagens baseado em lógica *fuzzy*. As figuras 19, 20 e 21 mostram as imagens originais (esquerda) e as imagens segmentadas (direita), utilizando a lógica *fuzzy* (LI e LI, 2008). Com isso, as três imagens originais fazem parte de um conjunto de imagens de ressonância magnética (tumores cerebrais) (HASHEMI, 2023). Já as figuras 22, 23 e 24 apresentam o resultado obtido com a segmentação de imagens mamográficas da base DDSM (HEATH et al., 1998, 2001)

Figura 19 - Imagens: original (esquerda) e segmentada (direita)

Imagem original



Imagem segmentada



Fonte: HASHEMI, 2023

Figura 20 - Imagens: original (esquerda) e segmentada (direita)

Imagem original



Imagem segmentada



Fonte: HASHEMI, 2023

Figura 21- Imagens: original (esquerda) e segmentada (direita)

Imagem original




Imagem segmentada



Fonte: HASHEMI, 2023.

Figura 22 - Imagens: original (esquerda) e segmentada (direita)

Imagem original




Imagem segmentada



Fonte: HEATH *et al.*, 1998, 2001

Figura 23 - Imagens: original (esquerda) e segmentada (direita)

Imagem original




Imagem segmentada



Fonte: HEATH *et al.*, 1998, 2001

Figura 24 - Imagens: original (esquerda) e segmentada (direita)

Imagem original




Imagem segmentada



Fonte: HEATH *et al.*, 1998, 2001

Os pacotes utilizados para segmentação das imagens das figuras 19, 20, 21, 22, 23 e 24 foram *imager* (BARTHELME, 2023) e *imagerExtra* (OCHI, 2019) e o código para gerar as imagens:

```
### carregando a imagem
I <- load.image("nome_do_arquivo")
# convertendo o imagem
I <- grayscale(I)
layout(matrix(1:2, 1, 2))
# visualizando as imagens
plot(I, axes = FALSE, main= "Imagem original")
ThresholdFuzzy(I) %>% plot(axes=FALSE, main= "Imagem segmen-
tada)
```


Capítulo 4

ESTE CAPÍTULO REFERE-SE:

- Redução de ruído em imagens
- Filtro de difusão anisotrópica
- Aplicação envolvendo a redução de ruído em imagens de radiografia de tórax

4.1. Redução de ruído em imagens

As imagens médicas são obtidas principalmente de equipamentos de ressonância magnética, tomografia computadorizada, raios-X, etc. O ruído sempre existe em alguma quantidade nas imagens e podem ser (PATIL E BHOSALE, 2022):

- gaussiano: espalha-se por toda a imagem e o valor do pixel da imagem corrompida (pelo ruído) é a soma do valor real do pixel (sem ruído) e da distribuição gaussiana;
- sal e pimenta: aparece na imagem como pequenos pontos brancos e pretos. O valor mínimo do *pixel* é ponto preto e o valor máximo ponto branco;
- periódico: é gerado por uma interferência elétrica, que geralmente surge durante a aquisição da imagem;
- branco: é totalmente não correlacionado, ou seja, cada valor de pixel não está relacionado aos pixels vizinhos;
- shot: tem distribuição de *Poisson*;
- multiplicativo: degrada a imagem de ultrassom, o que reduz o contraste;

- Rician: a intensidade do ruído em uma imagem de ressonância magnética segue a distribuição de Rician;
- Rayleigh: junto com os ruídos gaussiano e Riciano, estão presentes, principalmente, em imagens de ressonância magnética.

O objetivo da redução de ruído em uma imagem é obter uma imagem sem ruído a partir de uma imagem corrompida. A imagem corrompida é o resultado da soma da imagem sem ruído, com o ruído.

Os métodos de redução/remoção de ruído podem ser classificados em (MOHAN *et al.*, 2014):

- baseados em filtros: são métodos convencionais para redução de ruído, de modo que são divididos em lineares e não lineares, além de serem aplicados diretamente nas imagens;
- baseados em transformações: converte as imagens do domínio espacial para o domínio de frequência. As operações de filtragem ocorrem no domínio de frequência e, posteriormente, a filtragem é aplicada à transformação inversa, convertendo as imagens do domínio de frequência para o espacial;
- baseados em estatística: geralmente o ruído presente em imagens de ressonância magnética é modelado com ajuda de uma distribuição Rician. Uma etapa essencial na remoção de ruído é estimar a variância do ruído em imagens de ressonância magnética, já que essa estimativa é importante na redução de ruído;
- baseados em aprendizado de máquina: utilizam algoritmos computacionais com a propriedade de autoaprendizagem e se aprimoram por meio do treinamento.

4.2. Difusão Anisotrópica

Fenômenos físicos podem ser descritos matematicamente utilizando equações que envolvem derivadas parciais, isto porque as entidades físicas envolvidas são funções que dependem, geralmente, de mais de uma variável. As equações diferenciais parciais (EDPs) constituem uma ferramenta importante da matemática, uma vez que são usadas para modelar problemas significativos, entre eles, podemos citar problemas das engenharias e ciências naturais.

Existem muitos algoritmos baseados em EDPs para remoção de ruído e realce de imagem (LINGURARU E BRADY, 2001). A difusão anisotrópica tem origem no trabalho de Perona e Malik (1990), bem como é usada para filtrar imagens médicas, reduzindo o ruído e melhorando a interpretação das mesmas (TEBINI et al., 2017). O filtro de difusão anisotrópica obtém imagens suavizadas a partir da imagem com ruído, de forma que estas imagens são obtidas a partir da solução da EDP (MAISELI, 2023):

$$u_t = \operatorname{div}(f(|\nabla u|)\nabla u) \quad (1)$$


onde $u_0(x, y, 0)$ representa a imagem com ruído.

4.3. Aplicação

As imagens médicas constantemente são corrompidas por ruído durante o processo de aquisição ou transmissão, resultando em imagens de baixa qualidade. O ruído é um sinal indesejado que degrada informações importantes da imagem. Para uma análise e diagnóstico adequados, a remoção de ruído é necessária.


Nesse sentido, a aplicação descrita a seguir utiliza o filtro de difusão anisotrópica para remoção de ruído. As figuras 26, 28 e 30 mostram o resultado obtido após aplicação do filtro por Perona e Malik (1990), nas imagens das figuras 25, 27 e 29, com ruído. As imagens, deve-se salientar, fazem parte de um conjunto de um Banco de dados de radiografia de tórax (Chowdhury *et al.* 2020; Rahman *et al.*, 2021).

Figura 25 - Imagem da base de imagens com ruído




Fonte: Chowdhury *et al.* 2020; Rahman *et al.*, 2021

Figura 26 - Imagem da base de imagens filtrada



Fonte: Chowdhury *et al.* 2020; Rahman *et al.*, 2021

Figura 27 - Imagem da base de imagens com ruído




Fonte: Chowdhury *et al.* 2020; Rahman *et al.*, 2021

Figura 28 - Imagem da base de imagens filtrada




Fonte: Chowdhury *et al.* 2020; Rahman *et al.*, 2021

Figura 29 - Imagem da base de imagens com ruído



Fonte: Chowdhury *et al.* 2020; Rahman *et al.*, 2021

Figura 30 - Imagem da base de imagens filtrada



Fonte: Chowdhury *et al.* 2020; Rahman *et al.*, 2021

O pacote utilizado nos testes foi *imager* (BARTHELME, 2023), e o código para gerar as figuras 25, 26, 27, 28, 29 e 30 é:

```
# carregando a imagem
g0<-load.image("nome_do_arquivo")
# inserindo ruído e visualizando a imagem com ruído
im.ruído<-(g0+0.1*rnorm(prod(dim(g0))))    %>%    plot(axes=FAL-
SE,main="Imagem com ruído")
```

```
# aplicando o filtro de difusão anisotrópica e visuzalizando a imagem
filtrada
blur_anisotropic(im.ruido,amplitude = 1e3,sharpness = 1,alpha=4,
                 gauss_prec = 4) %>% plot(axes=FALSE,main="Imagem
filtrada")
```

Referências

ALCOFORADO, L. Ferreira. **Utilizando A Linguagem R: Conceitos, manipulação, visualização, modelagem e elaboração de relatórios**. Alta Books, 2021.

ALLAIRE, J. J.; CHOLLET, F. Keras: R Interface to 'Keras', **R package version 2.11.1**, 2023.

ALLAIRE, J. J.; TANG, Y., F. Tensorflow R Interface to 'Tensorflow', **R package version 2.14.0**, 2023.

ALOM, Md Zahangir et al. A state-of-the-art survey on deep learning theory and architectures. **electronics**, v. 8, n. 3, p. 292, 2019.

ASLANI, S.; JACOB, J. Utilisation of deep learning for COVID-19 diagnosis. Clinical **Radiology**, v. 78, n. 2, p. 150-157, 2023.

BEELEY, C. **Web application development with R using Shiny**. Packt Publishing Ltd, 2016.

BUKHARI, S. U. K. et al. The diagnostic evaluation of Convolutional Neural Network (CNN) for the assessment of chest X-ray of patients infected with COVID-19. **MedRxiv**, p. 2020.03. 26.20044610, 2020.

CARLSON, D. L. **Quantitative methods in archaeology using R**. Cambridge University Press, 2017.

CHAIRA, T.; RAY, A. K.. **Fuzzy image processing and applications with *MATLAB***. CRC Press, 2017.

CHITRADEVI, B.; SRIMATHI, P. An overview on image processing techniques. **International Journal of Innovative Research in Computer and Communication Engineering**, v. 2, n. 11, 2014, p. 6466-6472.

CHOLLET, F.; ALLAIRE J. J. **Deep Learning with R**. Manning Publications, 2018.

CHOWDHURY, Muhammad et al. Can AI help in screening viral and COVID-19 pneumonia? **IEEE Access**, v. 8, p. 132665-132676, 2020.

DAFFNER, R. H. **Radiologia Clínica Básica**. 3 ed. SAO PAULO: Manole, 2013.

DA SILVA, A. M. M.; PATROCÍNIO, A. C.; SCHIABEL, H. Processamento e análise de imagens médicas. **Revista Brasileira de Física Médica (online)**, 2019.

DÓCUSSE, T. A. **Um método para melhoria de qualidade de imagens médicas utilizando a transformada *wavelet***, Dissertação de Mestrado, UNESP, São José do Rio Preto, São Paulo, 2008.

DONG, Chao et al. Learning a deep convolutional network for image super-resolution. In: **Computer Vision—ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part IV 13**. Springer International Publishing, 2014. p. 184-199.

DOUGHERTY, G. **Digital image processing for medical applications**. Cambridge University Press, 2009.

EISBERG, R. M.; RESNICK, R. **Física Quântica**. 9ª ed. Campos, Rio de Janeiro, 1994.

FILHO, O. M.; NETO, H. V. **Processamento digital de imagens**. Braspot, Rio de Janeiro, Rio de Janeiro, 1999.

FREEPICK, 2024. Disponível em: https://br.freepik.com/fotos-gratis/sala-de-maquinas-de-tomografia-computadorizada-de-alto-angulo_24482132.htm#query=ressonancia%20magnetica&position=1&from_view=keyword&track=ais&uuid=62df9261-9a-4c-47ac-a88b-bf6bb011a57e>Freepik</a Acesso em: 10 de Maio de 2024.

FREITAS, A. G. Mamografia digital: perspectiva atual e aplicações futuras. **Radiologia Brasileira**, Vol. 39, pag 287-296, 2006

GONZALES, R. C.; WOODS, R. E. **Digital image processing**. 2nd ed. Upper Saddle River: Prentice-Hall, 2002.

GONZALES, R. C.; WOODS, R. E. **Processamento digital de imagens**. 3ª Ed. Pearson, São Paulo, 2010.

HAGE, M. C. F. N. S.; IWASAKI, M. Imagem por ressonância magnética: princípios básicos. **Ciência Rural**, v. 39, p. 1275-1283, 2009.

HALLIDAY, D.; RESNICK, R. **Física**, 10ª Edição. Vol. 4, Rio de Janeiro: Livros Técnicos e Científicos Editora, 2016.

HASHEMI, M. Hossein. **Crystal clean**: Brain tumors MRI dataset. 2023.

HEATH, Michael et al. Current status of the digital database for screening mammography. In: **Digital Mammography**: Nijmegen, 1998. Dordrecht: Springer Netherlands, 1998, p. 457-460.

HEATH, M. et al., The Digital Database for Screening Mammography. In: **Proceedings of the Fifth International Workshop on Digital Mammography**, M. J. Yaffe, ed., Medical Physics Publishing, 2001, 212-218.

HORE, A; ZIOU, D. Image quality metrics: PSNR vs. SSIM. In: **2010 20th international conference on pattern recognition**. IEEE, 2010. p. 2366-2369.

KAUR, P.; CHAIRA, T.. A novel fuzzy approach for segmenting medical images. **Soft Computing**, v. 25, n. 5, p. 3565-3575, 2021.

LI, L.; LI, D. Fuzzy entropy image segmentation based on particle swarm optimization. **Progress in Natural Science**, v. 18, n. 9, p. 1167-1171, 2008.

LINGURARU, M. G.; BRADY, M. An Anisotropic Diffusion Approach for Early Detection of Breast Cancer. **Acta Universitatis Cibiniensis. Technical Series**, v. 43, p. 49--60, 2001.

MAIER, Andreas et al. A gentle introduction to deep learning in medical image processing. **Zeitschrift für Medizinische Physik**, v. 29, n. 2, p. 86-101, 2019.

MAISELI, B. Nonlinear anisotropic diffusion methods for image denoising problems: Challenges and future research opportunities. **Array**, v. 17, p. 100265, 2023.

MARCHIORI E.; SANTOS M. L. **Introdução a Radiologia**. 2ª ed. Rio de Janeiro: Guanabara Koogan, 2015.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, p. 115-133, 1943.

MIRANDA, E.; ARYUNI, M.; IRWANSYAH, E. A survey of medical image classification techniques. In: **2016 international conference on information management and technology (ICIMTech)**. IEEE, 2016, p. 56-61.

MOHAN, J.; KRISHNAVENI, V.; GUO, Yanhui. A survey on the magnetic resonance image denoising methods. **Biomedical signal processing and control**, v. 9, p. 56-69, 2014.

NIST (Berger MJ et al). XCOM: Photon Cross Sections Database. Disponível em: <http://physics.nist.gov/PhysRefData/Xcom/Text/XCOM.html>. Acesso em: 16 de Maio de 2024.

OKUNO, E.; YOSHIMURA, E. M. **Física das radiações**. Oficina de textos, São Paulo, 2010.

PATIL, R.; BHOSALE, S.. Medical image denoising techniques: a review. **International Journal on Engineering, Science and Technology (IJonEST)**, v. 4, n. 1, p. 21-33, 2022.

PERONA, P.; MALIK, J.. Scale-space and edge detection using anisotropic diffusion. **IEEE Transactions on pattern analysis and machine intelligence**, v. 12, n. 7, p. 629-639, 1990.

RAHMAN, Tawsifur et al. Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. **Computers in biology and medicine**, v. 132, p. 104319, 2021.

RAMESH, Kumar K. D. et al. A review of medical image segmentation algorithms. **EAI Endorsed Transactions on Pervasive Health and Technology**, v. 7, n. 27, p. 1-9, 2021.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. R Foundation for Statistical Computing, 2022.

ROSA, R. O. **Estudos de parâmetros físicos de qualidade de imagem em mamografia convencional usando o método monte Carlo**. 2005. Tese (Doutorado) - UNIVERSIDADE FEDERAL DO RIO DE JANEIRO, Rio de Janeiro, 2005.

RSTUDIO TEAM. **RStudio: Integrated Development for R**. RStudio, Inc., Boston, MA, 2021.

SAMALA, Ravi K. et al. Multi-task transfer learning deep convolutional neural network: application to computer-aided diagnosis of breast cancer on mammograms. **Physics in Medicine & Biology**, v. 62, n. 23, p. 8894, 2017.

SARKER, Iqbal H. Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions. **SN Computer Science**, v. 2, n. 6, p. 420, 2021.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.

SHIN, HOO-CHANG et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. **IEEE transactions on medical imaging**, v. 35, n. 5, p. 1285-1298, 2016.

SINHA, P.; TUTEJA, M.; SAXENA, S. Medical image segmentation: hard and soft computing approaches. **SN Applied Sciences**, v. 2, p. 1-8, 2020.

SMITHA, P.; SHAJI L.; MINI, M. G.. A review of medical image classification techniques. In: **International conference on VLSI, Communication & Intrumrnataiom**. 2011, p. 34-38.

TAUHATA, L. et al. **Radioproteção e dosimetria: fundamentos**. CBPF, 2003.

TEAM, R. C. R: **A language and environment for statistical computing**. Vienna, Austria 2023.

TEBINI, S.; SEDDIK, H.; BRAIEK, E. B. Medical image enhancement based on New anisotropic diffusion function. In: **2017 14th International Multi-Conference on Systems, Signals & Devices (SSD)**. IEEE, 2017. p. 456-460.

THOMÉ, A. G.; **Aquisição e Representação da Imagem Digital**. 2024. Disponível em:

https://efaidnbmnnnibpcajpcgclclefindmkaj/https://hpc.ct.utfpr.edu.br/~charlie/docs/PID/PID_AULA_09.pdf. Acesso em: 10 de Maio de 2024.

VLAMOU, E.; PAPADOPOULOS, B. Fuzzy logic systems and medical applications. **AIMS neuroscience**, v. 6, n. 4, p. 266, 2019.

WANI, M. Arif et al. **Advances in deep learning**. Springer, 2020.

WIKIMEDIA COMMONS, 2024. Disponível em: https://commons.wikimedia.org/wiki/File:Espectro_Eletromagn%C3%A9tico.png Acesso em: 10 de Maio de 2024.

YAMASHITA, RIKIYA et al. Convolutional neural networks: an overview and application in radiology. **Insights into imaging**, v. 9, p. 611-629, 2018.

YANG, Yijun et al. Diffmic: Dual-guidance diffusion network for medical image classification. In: **International Conference on Medical Image Computing and Computer-Assisted Intervention**. Cham: Springer Nature Switzerland, 2023. p. 95-105.

YUHENG, S.; HAO, Y. Image segmentation algorithms overview. **arXiv preprint arXiv:1707.02051**, 2017.

ZADEH, L. A. Fuzzy sets. **Information and control**, v. 8, n. 3, p. 338-353, 1965.

André Luiz Nogueira

Graduação em Matemática (Licenciatura) pela Universidade Estadual Paulista Júlio de Mesquita Filho. Mestrado em Matemática Aplicada pela Universidade Estadual Paulista Júlio de Mesquita Filho. Doutorado em Tecnologia Nuclear pela Universidade de São Paulo – USP. Atualmente é professor efetivo do Instituto Federal de Sergipe. Tem experiência na área de Matemática Aplicada, com ênfase em Análise Multivariada e Processamento de Imagens, atuando principalmente nos seguintes temas: imputação de dados, detecção de outliers, padronização de dados, reconhecimento de faces, redes neurais e lógica *fuzzy*.



Hamona Novaes dos Santos

Possui graduação em Física (Licenciatura) pela Universidade Estadual do Sudoeste da Bahia. Mestrado em Física da Matéria Condensada pela Universidade Federal de Sergipe – UFS. Doutorado em Tecnologia Nuclear pela Universidade de São Paulo – USP. Atualmente é professora do Instituto Federal de Sergipe. Tem experiência na área de Física, com ênfase em Física da Matéria Condensada, Física Médica e Tecnologia nuclear, atuando principalmente nos seguintes temas: dosimetria, termoluminescência, ROLLIS, câncer de mama e processamento de imagens médicas.



Este livro mergulha no **fascinante mundo do processamento de imagens médicas**, utilizando a **linguagem de programação R** como ferramenta principal. A obra guia o leitor por um caminho claro e direto, explorando técnicas essenciais para: **classificação, segmentação e redução de ruído em imagens médicas**, utilizando a linguagem de programação R como ferramenta principal.

A primeira parte apresenta **conceitos básicos de processamento de imagens**, explorando técnicas de aquisição de imagens (raios-x e ressonância magnética) e introduzindo o R como ambiente de desenvolvimento. **Em seguida, o livro aborda a classificação de imagens, utilizando como ferramenta redes neurais profundas.** Através de um exemplo prático, o leitor aprende a utilizar uma **rede neural profunda pré-treinada (VGG19)** para classificar imagens de raios-x de toráx.

A segmentação de imagens é o foco da terceira parte. O leitor descobrirá **como isolar e delimitar regiões de interesse em imagens complexas**, utilizando um algoritmo baseado em lógica fuzzy, aplicado em **imagens de ressonância magnética**. A quarta parte trata da redução de ruído em imagens, uma etapa crucial para a obtenção de imagens mais **nítidas e com melhor qualidade**. O livro apresenta o filtro de difusão anisotrópica para redução de ruído em imagens mamográficas.