



UNIVERSIDADE ESTADUAL DE CAMPINAS  
Faculdade de Tecnologia

**Leonardo Ferrari Soares**

**Estudo de imagens de raio-x de pulmões acometidos pela  
covid-19 via técnica de re-ranqueamento de imagem**

Limeira  
2023

**Leonardo Ferrari Soares**

**Estudo de imagens de raio-x de pulmões acometidos pela covid-19 via  
técnica de re-ranqueamento de imagem**

Monografia apresentada à Faculdade de Tecnologia da Universidade Estadual de Campinas como parte dos requisitos para a obtenção do título de Bacharel em Sistemas de Informação, na área de Sistemas de Informação e Comunicação.

**Orientador: Prof. Dr. Marco Antonio Garcia de Carvalho**

Este trabalho corresponde à versão final da Monografia defendida por Leonardo Ferrari Soares e orientada pelo Prof. Dr. Marco Antonio Garcia de Carvalho.

Limeira  
2023

Ficha catalográfica  
Universidade Estadual de Campinas  
Biblioteca da Faculdade de Tecnologia  
Luiz Felipe Galeffi - CRB 8/10385

So11e Soares, Leonardo Ferrari, 1999-  
Estudos de imagens de raio-x de pulmões acometidos pela covid-19 via técnica de re-ranqueamento de imagem / Leonardo Ferrari Soares. – Limeira, SP : [s.n.], 2023.

Orientador: Marco Antonio Garcia de Carvalho.  
Trabalho de Conclusão de Curso (graduação) – Universidade Estadual de Campinas, Faculdade de Tecnologia.

1. Processamento de imagens - Técnicas digitais. 2. Recuperação de imagens baseada em conteúdo. 3. Re-ranqueamento. 4. Pulmões - Radiografia. 5. COVID-19, Pandemia de, 2020-. I. Carvalho, Marco Antonio Garcia de, 1970-. II. Universidade Estadual de Campinas. Faculdade de Tecnologia. III. Título.

Informações adicionais, complementares

**Título em outro idioma:** Study of x-ray images of lungs affected by covid-19 via image re-ranking technique

**Palavras-chave em inglês:**

Image processing - Digital techniques

Content-based image retrieval

Re-ranking

Lungs - Radiography

COVID-19 Pandemic, 2020-

**Titulação:** Bacharel

**Banca examinadora:**

Marco Antonio Garcia de Carvalho [Orientador]

Ana Estela Antunes da Silva

Luis Augusto Angelotti Meira

**Data de entrega do trabalho definitivo:** 28-06-2023

## FOLHA DE APROVAÇÃO

Abaixo se apresentam os membros da comissão julgadora da sessão pública de defesa de Trabalho de Conclusão de Curso para o Título de Bacharel em Sistemas de Informação na área de concentração Sistemas de Informação e Comunicação, a que se submeteu o aluno Leonardo Ferrari Soares, em 16 de junho de 2023 na Faculdade de Tecnologia – FT/UNICAMP, em Limeira/SP.

**Prof. Dr. Marco Antonio Garcia de Carvalho**  
Presidente da Comissão Julgadora

**Profa. Dra. Ana Estela Antunes da Silva**  
FT/UNICAMP

**Prof. Dr. Luis Augusto Angelotti Meira**  
FT/UNICAMP

Ata da monografia, assinada pelos membros da Comissão Examinadora, encontra-se no SIGA/Trabalho de Conclusão de Curso/Monografia e na Secretaria de Graduação da Faculdade de Tecnologia.

# Agradecimentos

Ao professor Marco, por todo auxílio, paciência e incentivo durante a orientação, tornando possível a conclusão desta monografia.

À universidade, expresso minha gratidão pela oportunidade de cursar e por fornecer um ambiente acolhedor e propício.

A todos que, direta ou indiretamente, contribuíram para o meu desenvolvimento e formação acadêmica.

Também gostaria de oferecer meus sinceros agradecimentos aos membros do corpo docente da universidade, que contribuíram com seus conhecimentos e experiências para enriquecer este trabalho.

# Resumo

Uma das maiores preocupações dos últimos anos foi a pandemia da Covid-19, causada pelo surto de coronavírus (SARS-CoV-2). Como resultado do rápido avanço da doença globalmente, hospitais em todo o mundo enfrentaram um grande número de pacientes, e alguns países, incluindo o Brasil, chegaram perto de um colapso em seus sistemas de saúde. Devido a esse acontecimento, um crescente volume de dados de imagem foram gerados nesses últimos tempos. Isso abriu oportunidades para o avanço de soluções baseadas em PDI (Processamento Digital de Imagens), que desempenha um papel fundamental no auxílio da imagiologia médica.

Dito isso, o presente trabalho tem como objetivo analisar e determinar a eficácia da combinação entre os descritores GLCM, LBP, e Histograma de intensidades, e o algoritmo de aprendizado não-supervisionado RL-Sim. Para isso, a técnica de Recuperação de Imagens Baseada em Conteúdo, ou *Content Based Image Retrieval* (CBIR), é utilizada, cujo objetivo é retornar uma lista ordenada das imagens mais relevantes e semelhantes à imagem de consulta. A lista ordenada é resultante da extração e comparação das características das imagens, sendo a extração feita através de descritores de imagem e a comparação feita através de funções de distância.

Como principal contribuição deste estudo, constatou-se que a aplicação do algoritmo RL-Sim não tem um impacto tão significativo para os descritores estudados. Nota-se, também, que o descritor GLCM apresentou ganhos após a aplicação do algoritmo RL-Sim.

# Abstract

One of the biggest concerns in recent years has been the Covid-19 pandemic, caused by the outbreak of the coronavirus (SARS-CoV-2). As a result of the rapid global spread of the disease, hospitals around the world have faced a large number of patients, and some countries, including Brazil, came close to a collapse in their healthcare systems. Due to this event, a growing volume of image data has been generated in recent times. This has opened up opportunities for advancements in solutions based on Digital

Image Processing (DIP), which plays a fundamental role in assisting medical imaging. That being said, the objective of this study is to analyze and determine the effectiveness of combining the GLCM, LBP, and Intensity Histogram descriptors with the unsupervised learning algorithm RL-Sim. For this purpose, the technique of Content-Based Image Retrieval (CBIR) is used, which aims to return a sorted list of the most relevant and similar images to the query image. The sorted list is the result of extracting and comparing the features of the images, with extraction performed using image descriptors and comparison carried out using distance functions.

The main contribution of this study is the finding that the application of the RL-Sim algorithm does not have a significant impact on the studied descriptors. It is also worth noting that the GLCM descriptor showed improvements after the application of the RL-Sim algorithm.

# Lista de Figuras

2.1	Total de casos covid-19 . . . . .	17
2.2	Imagem em escala de cinza ampliada . . . . .	18
2.3	CT Scan . . . . .	20
2.4	CT Scan . . . . .	21
2.5	Arquitetura típica de um sistema CBIR . . . . .	22
2.6	Divisão genérica da representação dos métodos de agregação de ranking. Fonte: (LINGARAJ, 2015). . . . .	24
2.7	Algoritmo de re-ranqueamento RL-Sim. . . . .	31
3.1	flowchart metodologia . . . . .	33
3.2	Técnica de aprimoramento CLAHE . . . . .	39
4.1	Algoritmo de re-ranqueamento RL-Sim pós GLCM. . . . .	46
4.2	Algoritmo de re-ranqueamento RL-Sim pós LBP. . . . .	46
4.3	Algoritmo de re-ranqueamento RL-Sim pós LBP. . . . .	47

# Lista de Tabelas

4.1	Tabela para P@4 . . . . .	45
4.2	Tabela para o MAP . . . . .	45

# Lista de Símbolos

- $\alpha$  Descrição do símbolo  $\alpha$ . utilize uma descrição curta. De preferência, que ocupe no máximo uma linha.
- $\beta$  Descrição do símbolo  $\beta$ .
- $\epsilon$  Função de extração de um vetor de características de uma imagem.
- $\rho$  Função de distância entre duas imagens.

# Lista de Abreviaturas e Siglas

CBIR	<i>Content Based Image Retrieval</i>
CCV	<i>Color Coherence Vector</i>
CLAHE	<i>Contrast Limited Adaptive Histogram Equalization</i>
CT	<i>Computed Tomography</i>
CXR	<i>Chest X-ray</i>
GCH	<i>Global Color Histogram</i>
GLCM	<i>Gray Level Co-occurrence Matriz</i>
LCH	<i>Local Color Histogram</i>
PDI	<i>processamento digital de imagens</i>
RA	<i>Rank Aggregation</i>
RR	<i>Re-ranking</i>
SRA	<i>Supervised Ranking Aggregation</i>

# Sumário

<b>1</b>	<b>Introdução</b>	<b>13</b>
1.1	Motivação e caracterização do problema . . . . .	13
1.2	Objetivos . . . . .	14
1.3	Estrutura do texto . . . . .	15
<b>2</b>	<b>Fundamentação Teórica</b>	<b>16</b>
2.1	A doença COVID-19 . . . . .	16
2.2	Processamento de imagens e imageamento médico . . . . .	18
2.2.1	Processamento de digital de imagens x visão computacional . . . . .	19
2.2.2	Imagiologia médica . . . . .	19
2.2.3	Imagens pulmonares . . . . .	20
2.3	CBIR . . . . .	21
2.4	Descritores . . . . .	21
2.4.1	Cor . . . . .	22
2.4.2	Textura . . . . .	23
2.4.3	Forma . . . . .	23
2.5	Ranking . . . . .	23
2.6	Agregação de Ranking . . . . .	24
2.6.1	Implementação . . . . .	26
2.7	Re-Ranqueamento de imagens . . . . .	26
2.7.1	Definição do problema . . . . .	28
2.7.2	Técnicas para re-ranqueamento de imagens . . . . .	29
2.8	Algoritmo RL-Sim . . . . .	29
2.8.1	Descrição matemática . . . . .	30
<b>3</b>	<b>Método proposto</b>	<b>32</b>
3.1	Materiais e Métodos . . . . .	32
3.1.1	Objetivos . . . . .	32
3.1.2	Dataset utilizado . . . . .	34
3.1.3	Descritores utilizados . . . . .	34
3.1.4	UDLF . . . . .	37
3.1.5	Enriquecimento da imagem . . . . .	38
3.1.6	Extração de características . . . . .	38
3.1.7	Aprendizado Não-Supervisionado . . . . .	39
3.1.8	Uso da Linguagem Python . . . . .	40

<b>4</b>	<b>Resultados</b>	<b>42</b>
4.1	Desenvolvimento do código . . . . .	42
4.1.1	Cálculo de Precisão . . . . .	44
4.2	Métricas . . . . .	45
<b>5</b>	<b>Considerações Finais</b>	<b>49</b>
	<b>Referências bibliográficas</b>	<b>51</b>

# Capítulo 1

## Introdução

### 1.1 Motivação e caracterização do problema

Hoje em dia, a maior preocupação que enfrentamos é a causada pelo surto de coronavírus (SARS-CoV-2), causador da Covid-19. A doença, altamente infecciosa, se espalhou apressadamente pelo mundo todo, causando um impacto que há muito tempo não se via. A repercussão deste impacto pode ser vista em diversos sistemas sociais: Empresas, escolas, economia e principalmente em hospitais. Até o presente momento, estima-se que ao menos mais de 254 milhões de pessoas tenham sido acometidos pela doença e, dentre esses 254 milhões infectados, 5 milhões morreram.

Como resultado desta pandemia, os hospitais de todo o mundo receberam um grande número de pacientes e, dentre todos os países, quase tivemos um colapso no sistema de saúde em alguns deles, incluindo o Brasil. Conseqüentemente, o número de oportunidades para o avanço de soluções baseadas em tecnologia aumentou, e com isso proporcionou uma rara oportunidade de estudar a pesquisa e a prática da tecnologia, incluindo gestão da informação, práticas de trabalho, design e uso de tecnologias (HE; ZHANG, Z. (; LI, W., 2021).

E no meio desta crescente tecnológica, temos o aprimoramento da tecnologia multimídia, onde o uso crescente de grandes bancos de dados de imagens torna-se cada vez mais palpável e, por conta disto, cada vez mais necessitamos de técnicas com bom desempenho e bons resultados na consulta dessas imagens. Para realizar a gestão e recuperação deste conteúdo, a Recuperação de Imagens Baseada em Conteúdo (*Content Based Image Retrieval* – CBIR) é um método eficaz.

A necessidade mais importante de qualquer modelo de recuperação de imagens é pesquisar e organizar as imagens que contém alguma relação semântica visual com a consulta fornecida pelo usuário. Para recuperar qualquer imagem, temos que procurá-la no banco de dados usando algum mecanismo de busca. Então, este motor de busca irá recuperar muitas das imagens relacionadas com a consulta original. A maioria dos motores de busca na Internet recupera as imagens com base em abordagens baseadas em texto que requerem legendas como entrada (YANG et al., 2019). O usuário envia uma consulta inserindo algum texto ou palavras-chave que correspondam às palavras-chave colocadas no arquivo. A saída é gerada com base na correspondência de palavras-chave e esse processo pode recuperar as imagens que não são relevantes.

O principal problema encontrado é a dificuldade de localizar uma imagem relevante na grande coleção e variada de imagens resultantes. Esse é um problema de busca de imagens digitais em grandes bancos de dados, conhecido como problema de recuperação de imagem. Para resolver este problema, iremos explorar mais a fundo duas técnicas de pesquisa e recuperação em um banco de dados de imagens baseadas em conteúdo: Re-ranqueamento e Agregação de Rankings.

## 1.2 Objetivos

A pandemia da Covid-19 gerou um grande volume de dados de imagem, que podem ser usados para o avanço de soluções baseadas em PDI. O objetivo do presente trabalho é o de analisar e determinar a eficácia da combinação entre os descritores GLCM, LBP, e Histograma de intensidades, e o algoritmo de aprendizado não-supervisionado RL-Sim. Para isso, temos como objetivos específicos:

- Realizar um levantamento bibliográfico sobre descritores e métodos de ranqueamento de imagens de raio X de pulmão.
- Estudo e avaliação da aplicabilidade do método de Aprendizado Não-Supervisionado RL-Sim visando aumentar a eficácia de sistemas MIR.
- Avaliar se a utilização da combinação de descritores visuais de uso geral, com o RL-Sim, gera resultados melhores após o processo de recuperação.

### **1.3 Estrutura do texto**

As demais informações acerca do texto foram ordenadas da seguinte forma: o Capítulo 2, Fundamentação Teórica, aborda conceitos fundamentais de processamento digital de imagens, a doença Covid-19, CBIR e métodos de ranqueamento para MIR. O Capítulo 3 explica o método proposto utilizado no trabalho, englobando as informações teóricas e de implementação da técnica. O Capítulo 4 traz o plano de trabalho e organização da proposta do Trabalho de Conclusão de Curso. Por fim, o Capítulo 5 expõe as conclusões e passos futuros para o tema.

# Capítulo 2

## Fundamentação Teórica

Inicialmente foi feito um estudo sobre CBIR, re-ranqueamento e agregação de rankings, levando em conta diversos descritores que poderiam ser utilizados aqui, fundamentando assim o projeto. Nos principais conceitos discutidos nesta seção, começamos pela explicação do que é a doença COVID-19, abordando a doença e as consequências que ela causou no mundo todo; na segunda temos a definição do que é processamento de imagens e imageamento médico, detalhando o conhecimento a respeito do assunto; a terceira explica de forma objetiva o que é um sistema CBIR; a quarta esclarece mais a respeito do processo de ranqueamento de imagens e a aplicação de técnicas existentes; na quinta temos a elucidação do método de agregação de ranking e exemplos acerca do método.

### 2.1 A doença COVID-19

Covid-19 é uma doença infecciosa causada pelo vírus SARS-CoV-2, da família dos coronavírus, que ao infectar um humano pode levá-lo a óbito em pouco tempo. Devido a algumas de suas características genéticas, as pessoas estão mais suscetíveis a serem contaminadas por este agente infeccioso. Os primeiros registros da covid-19 aconteceram em Wuhan, na China, em dezembro de 2019, e, por conta da rápida transmissão do vírus, em pouco tempo a doença já havia se estabelecido em diversos países do mundo, como representado no número de casos da figura 2.1. Até o momento existem duas hipóteses que mais se aproximam da origem do vírus (ANDERSEN et al., 2020): A primeira engloba a transmissão direta, através do consumo do morcego pelo homem, e a segunda diz que o vírus passou do morcego para um mamífero intermediário, e dele para o ser humano.

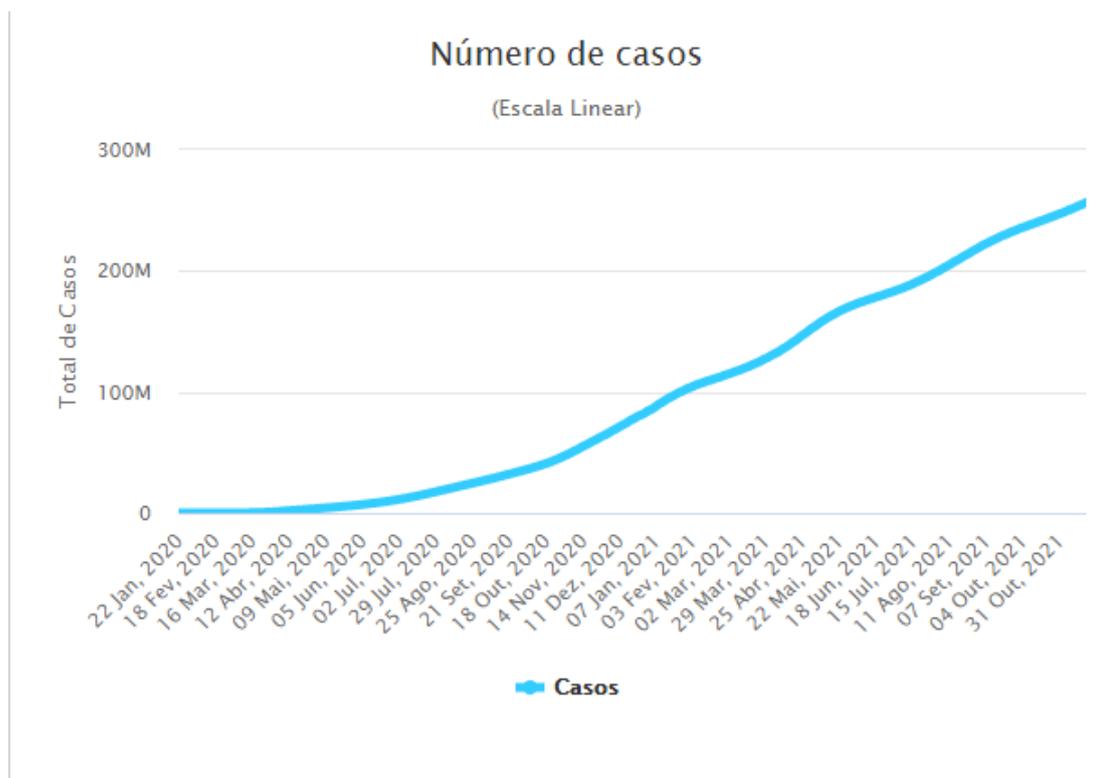


Figura 2.1: Imagem representando o número de casos de Covid-19 desde seu surgimento. Fonte: (WORLDMETERS, 2021).

Com sistemas extremamente diversificados, o vírus afeta não só o sistema respiratório como também diversos outros órgãos do corpo humano. Estudos epidemiológicos têm mostrado que as mortalidades são maiores na população idosa e a incidência é muito menor em crianças (YUKI; FUJIOGI; KOUTSOGIANNAKI, 2020). Por conta disto, um grande número de países implementou o distanciamento social e *lockdowns* para mitigar a propagação do vírus.

Essa adaptação aos desafios que se ergueram, em consequência deste evento, alteraram o comportamento e atitudes que antes eram rotineiras para as pessoas. Os reflexos foram vistos em quase todos os setores da sociedade, com destaque para a área hospitalar. Dentre as estratégias de combate ao perigo global, a disponibilização de leitos hospitalares para as pessoas acometidas pela doença foi um dos maiores problemas enfrentados, o que gerou uma crise sanitária, e humanitária, no país.

## 2.2 Processamento de imagens e imageamento médico

Existem diversas definições para o que se entende de imagem, e por conta dessa subjetividade ela pode adquirir um significado diferente em cada contexto. Do ponto de vista da computação, podemos estabelecer que uma imagem (digital) consiste em um array bidimensional, sendo esta composta por pixels representando a intensidade luminosa no ponto. A Figura 2.2 ilustra uma imagem em escala de cinza, onde cada pequeno quadrado é um *Pixel*, valor número que varia entre 0 e 255. Os computadores armazenam as imagens em um formato de matriz de números, onde cada número dessa matriz é um *Pixel*.

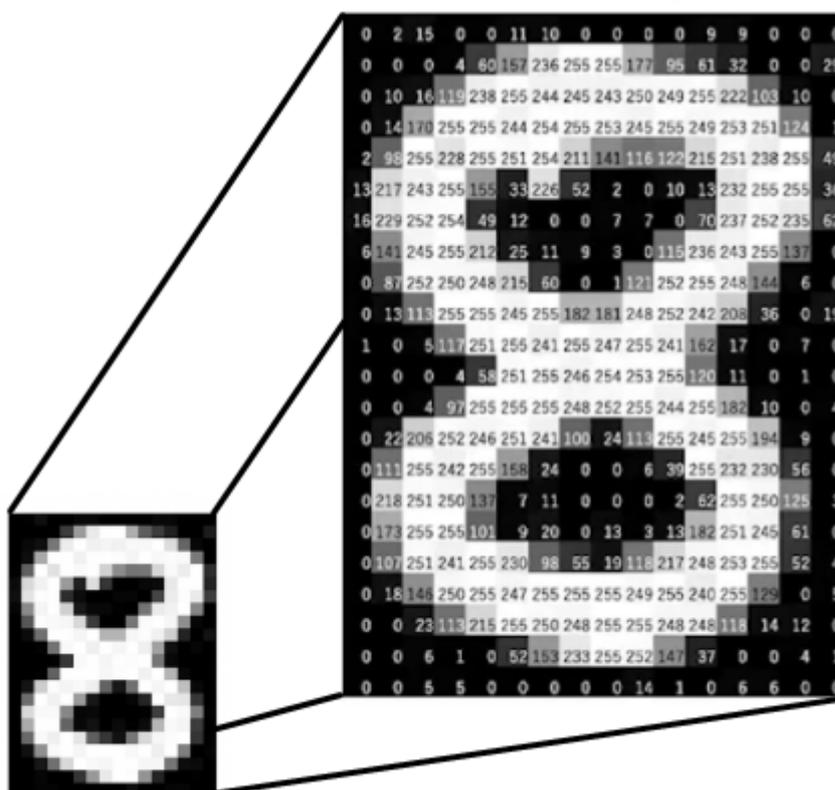


Figura 2.2: Imagem em escala de cinza ampliada, mostrando os pixels e seu respectivo valor (0 a 255). Fonte: (ANALYTICSVIDHYA, 2021).

O autor Gonzalez (GONZALEZ; WOODS, 2000) define *processamento digital de imagens* – PDI como o campo de processamento de imagens digitais por um computador, onde uma imagem digital é composta de um número finito de elementos, sendo um *Pixel* o termo mais utilizado para a representação de uma imagem digital. Posto isso, podemos dizer que PDI consiste em um conjunto de técnicas voltadas para a análise de dados multidimensionais com o auxílio de um computador. Um dos exemplos de uso está na busca pelo aperfeiçoamento do aspecto visual de certos formatos estruturais para posteriormente ser submetido a outros

processamentos. Esta técnica envolve processos cujas entradas e saídas são imagens e, além disso, envolve processos de extração de atributos de imagens até, e inclusive, o reconhecimento de objetos individuais. Dito isso, é importante entendermos qual a diferença entre PDI e visão computacional.

### **2.2.1 Processamento de digital de imagens x visão computacional**

Como supracitado, o processamento digital de imagens faz uso de técnicas para a preparação da imagem, com o objetivo de aperfeiçoamento e melhora da qualidade da mesma. Além disso, o processamento é utilizado como em CBIR, onde exerce a função de extrair informações para futuro tratamento por alguma técnica em específica. E uma dessas possíveis técnicas é a visão computacional, que tem como objetivo desenvolver a habilidade de enxergar e compreender o conteúdo de alguma mídia multidimensional, como fotos e vídeos. A diferença entre esses dois macrotemas está na finalidade de cada um: enquanto em PDI buscamos uma imagem de entrada para uma ou mais imagens de saída, em visão computacional temos como objetivo simular a visão humana (GONZALEZ; WOODS, 2000), muitas vezes utilizando algum método de aprendizado de máquina e inteligência artificial. Dito isso, podemos concluir que visão computacional está mais ligada a área de estudo de inteligência artificial do que a área de aprimoramento do conteúdo (imagem).

### **2.2.2 Imagiologia médica**

Após a crescente evolução tecnológica da área de PDI, diversos sistemas de diagnóstico por imagem começaram a ganhar espaço na área médica e a importância das técnicas desse ramo também. Hoje, o imageamento médico é uma ferramenta essencial em um diagnóstico (ZHANG, X.; SMITH; WEBB, 2008), melhorando os resultados de tratamento médico e ampliando as possibilidades para avanço na área médica. Essas imagens podem ser formadas por diversas técnicas, tal como banda ultravioleta, raios gama, raios X, banda infravermelha e etc. Dentre essas, temos um dos métodos mais significativos para a área de processamento digital de imagens, no ramo da medicina: A tomografia computadorizada, processo no qual a imagem é formada através de uma fonte de raios X. Abaixo temos uma explicação mais detalhada acerca dos processos utilizados no trabalho.

### 2.2.3 Imagens pulmonares

Em março de 2020, houve um aumento na publicação de raios X disponíveis de casos saudáveis, mas também de pacientes sofrendo da Covid-19. Isso permite o estudo das imagens médicas e identificação de possíveis padrões que podem levar ao diagnóstico automático da doença (APOSTOLOPOULOS; MPESIANA, 2020). A dificuldade em se obter um rápido diagnóstico ao analisar doenças pulmonares é um trabalho que exige um nível de conhecimento vasto do profissional da saúde, isto devido às diversas variáveis que podem ser encontradas neste conjunto de doenças. Dentre os tipos de imagens, temos algumas técnicas mais significativas:

#### Tomografia computadorizada

A Tomografia computadorizada (*Computed Tomography – CT*) é um método de imagem que utiliza fonte raios X e programas capazes de gerar uma visualização de alta qualidade (HATHCOCK; STICKLE, 1993). Esta visualização é dada por diversas fatias, gerada por capturas em vários ângulos, proporcionando uma avaliação multidimensional (2D ou 3D), de um setor corporal, de forma muito mais detalhada. Por conta disso, a CT se tornou uma ferramenta utilizada no suporte de diagnóstico da Covid-19 (PONTONE et al., 2021), ajudando no processo de classificação da doença, como demonstrado na figura 2.3.

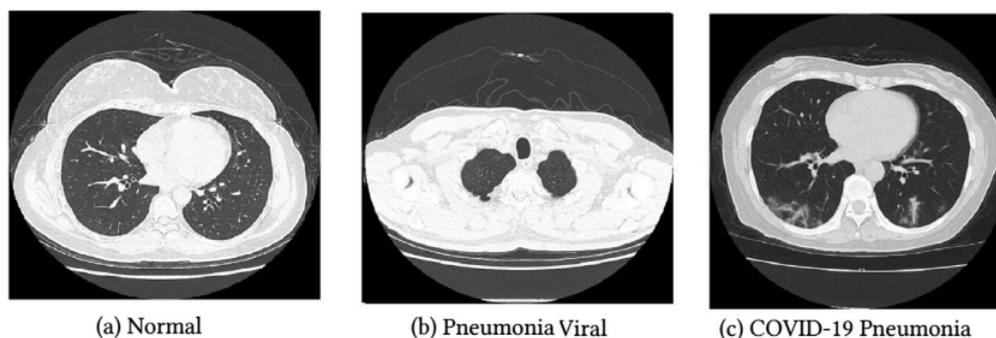


Figura 2.3: Imagens de uma tomografia computadorizada . Fonte: (BENMALEK; ELMHAMDI; JILBAB, 2021).

#### Imagens com raio-x

As imagens com raio-x (*Chest X-ray – CXR*), exame de imagem utilizado neste estudo, são produzidas quando elétrons acelerados colidem com um alvo metálico, criando assim imagens do interior do corpo. O método CXR pode oferecer resultados mais rápidos em comparação com outros métodos. Existem diversas áreas que utilizam o processo de radiografia, dentre elas

está a área médica, onde as imagens com raio-x exercem um importante papel no diagnóstico de doenças. A figura 2.4 ilustra exemplos de imagens capturadas pela emissão de raios-X

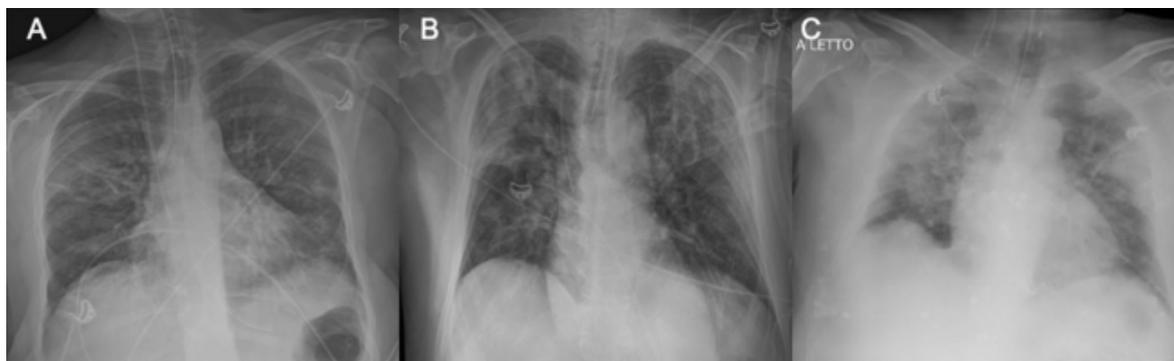


Figura 2.4: Raio X torácico de três pacientes com insuficiência respiratória grave. Fonte: (COZZI et al., 2020).

## 2.3 CBIR

A recuperação de imagens baseada em conteúdo (CBIR) é um dos desafios fundamentais da pesquisa extensivamente estudados na comunidade multimídia por décadas. CBIR visa buscar imagens através da análise de seus conteúdos visuais e, portanto, a representação da imagem é o ponto crucial do CBIR.

Na recuperação de imagens, o usuário pode enviar um exemplo de consulta ao sistema de recuperação para pesquisar as imagens desejadas que são mais semelhantes com a imagem de entrada. O sistema retrata a consulta com um vetor de características, e então as distâncias, (ou seja, semelhanças), entre os vetores de características do exemplo de consulta, e aqueles da imagem no banco de dados de características, são calculadas e classificadas. Assim, o sistema classifica os resultados da pesquisa e, em seguida, retorna os resultados que são mais semelhantes aos exemplos de consulta. Uma arquitetura típica para o sistema CBIR é ilustrada na Figura 2.5.

## 2.4 Descritores

Descritores de imagens, em problemas de CBIR, são meios utilizados com a finalidade organizar e identificar as imagens no espaço de busca. Estes descrevem as características através de recursos visuais, sendo os principais cor, textura e forma (SHAKARAMI; TARRAH, 2020). Os

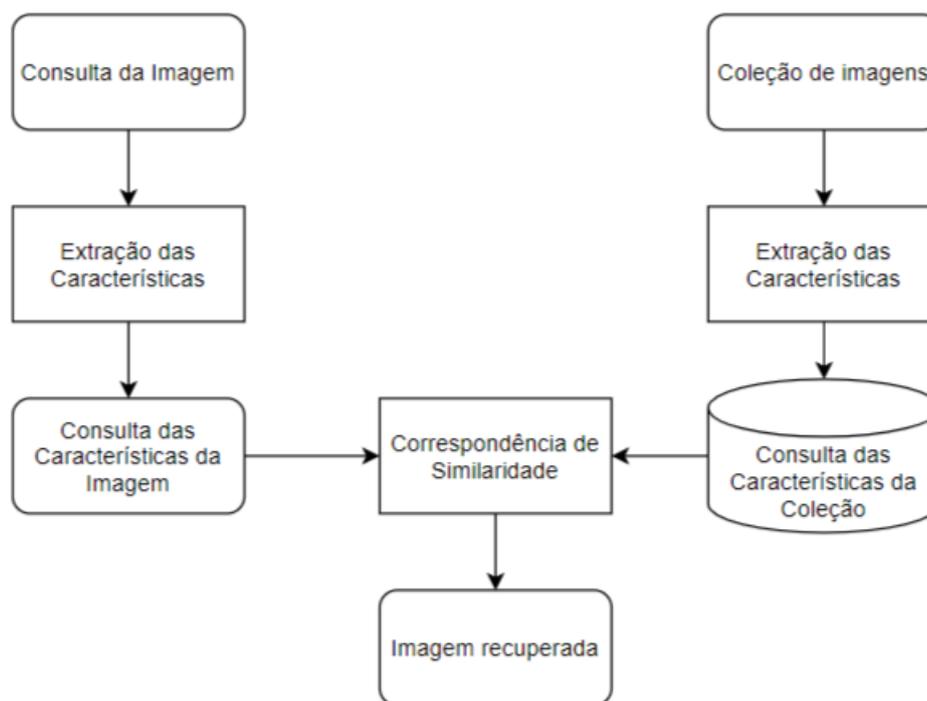


Figura 2.5: Arquitetura típica de um sistema CBIR. Fonte: (LINGARAJ, 2015).

três tipos de descritores supracitados são usados para extrair um vetor de características das imagens.

### 2.4.1 Cor

Cor é um atributo comumente utilizado para descrição de conteúdos visuais, isto devido a importância da cor para a diferenciação do conteúdo, coisa que nós humanos somos capazes de ver. A pesquisa realizada por Almeida *et al* em 2008 (ALMEIDA *et al.*, 2008) traz três tipos de categorias destes descritores:

- Global-based: O conteúdo da imagem é retratado por inteiro, tal como o uso do *binning* de pixels em um histograma. Um exemplo é o descritor *Global Color Histogram* – GCH (YUE *et al.*, 2011).
- Partition-based: As características da imagem são obtidas através da partição de diversas regiões, analisando-as isoladamente. Um exemplo é o descritor *Local Color Histogram* – LCH (PENATTI, O. A.; VALLE; S. TORRES, 2012)

- Region-based: Pixels são agrupados, de acordo com a similaridade de sua disposição, em regiões, cada qual podendo ser, ou não, únicas. Um exemplo é o descritor *Color Coherence Vector* – CCV (PENATTI, O. A. B.; SILVA TORRES, 2008)

### 2.4.2 Textura

Uma definição formal, capaz de descrever um descritor de textura, ainda não é conhecida na literatura (KUMAR; SREEKUMAR, 2014), mas sabemos que ela também é um elemento importante usado pelo ser humano para distinção de diferentes tipos. Um conjunto de características recorrentes em todas texturas visuais foi proposto por alguns autores (TAMURA; MORI; YAMAWAKI, 1978), sendo estas: aspereza, contraste, direcionalidade, regularidade, rugosidade e a semelhança entre linhas. Um exemplo de descritor de textura é o *Gray Level Co-occurrence Matriz* – GLCM, que consiste em um método de análise estatística de imagens (ALSMADI, 2020) através da combinação de diferentes valores de pixels.

### 2.4.3 Forma

A forma dos objetos podem nos fornecem informação dedutível "a olho", isto é, podemos diferenciar pequenas séries de características através da observação direta de uma imagem. Contornos, bordas, junções são algumas das características visualmente perceptíveis que juntas formam uma representação da forma de um item de estudo (AKGÜL et al., 2011). Um exemplo é o método proposto por Qi *et al* em 2010 (AKGÜL et al., 2011), que utiliza um descritor de forma baseado no contorno chamado RAPC-HCD.

## 2.5 Ranking

O ranqueamento de imagens é um dos processos de CBIR, que visa obter um objeto de retorno similar ao de entrada, com a necessidade da lista retornada ser ordenada de acordo com a pertinência em relação à imagem consultada (SIDDIQUIE; FERIS; DAVIS, 2011). Devido á alta quantidade de resultados que podem ser retornados em uma consulta, é importante que os melhores resultados retornados sejam de alta qualidade para o usuário. Neste trabalho iremos usar uma estratégia mais comum baseada no uso de descritores (abordados na Seção 2.7)

## 2.6 Agregação de Ranking

Visando melhorar a acurácia de sistemas CBIR, algoritmos de reclassificação e agregação de listas (*Rank Aggregation* – RA) têm sido propostos. A reclassificação dos resultados (*Re-ranking* – RR) é um mecanismo proveniente do campo de recuperação de informações. Nesse mecanismo, o processo consiste em reavaliar as imagens após a busca inicial. Pode ser visto na literatura que existem duas abordagens para a implementação do esquema de re-ranqueamento: reclassificação antes de visualizar os resultados e reclassificar após a visualização. A última abordagem depende das informações de feedback de relevância, enquanto o anterior é baseado no primeiro resultados retornados pelo sistema, conhecidos como feedback de pseudo-relevância. Já a agregação de listas consiste no processo de combinar múltiplas listas ranqueadas, chamadas de listas base, em apenas uma lista conhecida como "classificação agregada", que se destina a ser mais confiável do que as listas base.

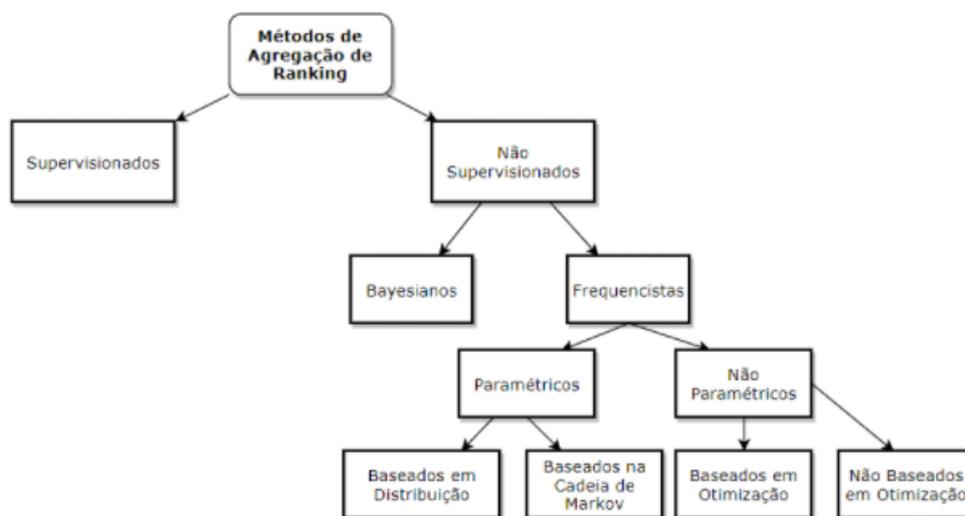


Figura 2.6: Divisão genérica da representação dos métodos de agregação de ranking. Fonte: (LINGARAJ, 2015).

Em geral, os métodos de AR podem ser divididos em duas categorias, como visto na figura 2.6: métodos supervisionados e métodos não supervisionados. Métodos supervisionados como agregação de classificação supervisionada (*Supervised Ranking Aggregation* – SRA) fazem uso de conjuntos de dados de treinamento contendo classificações

relativas verdadeiras de alguns itens por meio de algoritmos de aprendizagem. Como nenhum dado rotulado está disponível na maioria das aplicações, métodos não supervisionados de agregação de lista têm sido dominante na literatura. Dentre os métodos de agregação de lista não supervisionados temos uma primeira divisão entre dois grupos: **Bayesianos e Frequencistas** (LI, X.; WANG; XIAO, 2017).

Métodos Bayesianos:

- Dependem de certas quantidades de dados envolvidos na inferência posterior (tal como probabilidade posterior, Fator de Bayes) para determinar a classificação agregada.
- Pode ser usado métodos bayesianos específicos para cada tipo de problema

Métodos Frequencistas:

- Não Baseados em Otimização:
  - Alguns dos primeiros métodos de agregação, simplesmente usam estatísticas simples, como a média aritmética, mediana, média geométrica e regularização L2 de listas base para agregar dados de classificação.
- Baseados em Otimização:
  - Projetados para minimizar alguma medida de distância, de modo que o ranking agregado seja o mais próximo possível de todos os rankings básicos.
  - Com a disponibilidade de poder computacional moderno, eles tornaram-se mais viáveis. No entanto, normalmente precisam de muito mais tempo para executar do que outros métodos, especialmente para listas relativamente longas que ocorrem em configurações genômicas.
- Baseados em Distribuição:
  - Um método é categorizado como baseado em distribuição se assume um modelo latente probabilístico ou usa informações de distribuição de qualquer estatística calculada a partir dos dados de classificação.
- Baseados na Cadeia de Markov:
  - Desenvolvidos sob uma modelagem da Cadeia de Markov, onde a união dos itens de todas as listas base forma o espaço de estado.

- Uma matriz de transição é construída em uma forma tal que sua distribuição estacionária terá maiores probabilidades para estados com classificação superior.

### 2.6.1 Implementação

Conforme mencionado anteriormente, a agregação de ranking tem sido amplamente aplicada em vários campos. Campos de estudo dos genes e metapesquisa tendem a gerar "algumas listas ranqueadas longas", enquanto campos como marketing e sociologia tendem a gerar "poucas listas". Essas características inerentes aos dados disponíveis a partir de campos específicos faz com que certos métodos se tornem mais apropriados do que outros. Para trabalhar a implementação, podemos listar dois pacotes da linguagem de programação R que englobam grande parte dos métodos categorizados acima: "TopKLists" e "RobustRankAggreg".

## 2.7 Re-Ranqueamento de imagens

A definição de medidas de distância adequadas desempenha um papel fundamental em muitas aplicações de multimídia, incluindo tarefas de classificação, armazenamento em cluster e recuperação. Em geral, com o objetivo de recuperar as imagens mais semelhantes a uma imagem de consulta, os sistemas CBIR calculam uma medida de distância predefinida entre a consulta imagem e uma imagem no banco de dados. A semelhança entre qualquer par de objetos é calculado por alguma função de distância, sendo compreendido que baixos valores de distância correspondem a altos graus de similaridade. Medidas de distância tradicionais, como a distância euclidiana, consideram a semelhança de pares entre quaisquer duas imagens. Em muitas situações, estas abordagens não retornam resultados satisfatórios, principalmente devido ao conhecido problema de uma lacuna semântica.

Recentemente, muitos estudos têm demonstrado, tanto empiricamente quanto teoricamente, que uma medida aprendida pode melhorar significativamente a eficácia na classificação, agrupamento e recuperação. Em especial para os sistemas CBIR, tem havido pesquisas consideráveis sobre como melhorar as medidas de distância. Resultados promissores foram obtidos considerando várias abordagens e técnicas. Uma dessas abordagens é chamada de re-classificação de imagem, que é um dos principais focos desta tese.

Uma tarefa comum para sistemas CBIR é recuperar as imagens mais semelhantes a um padrão de consulta (por exemplo, imagem de consulta) definido pelos usuários. Em geral, a saída fornecida é uma lista classificada, onde as imagens são dispostas em ordem decrescente ordem de semelhança, de acordo com uma propriedade visual, como forma, cor e textura. Nesse cenário, classificar com precisão as imagens da coleção é de ótima relevância. Os sistemas existentes costumam considerar apenas a análise de pares, medindo a semelhança entre pares de imagens e ignorando as informações relevantes codificadas nas relações entre várias imagens. A percepção do usuário, em por outro lado, considera a especificação da consulta e as respostas em um determinado contexto.

Um dos pontos positivos do uso da abordagem de re-ranqueamento está no fato dela não necessitar de algum tipo de interferência do usuário, nem de dados de treinamento e/ou dados rotulados. Ou seja, o funcionamento se dá de maneira não-supervisionada. Algoritmos que utilizam algum tipo de aprendizado não-supervisionado procuram analisar os dados de referência e tentam determinar se alguns deles podem ser agrupados utilizando algum tipo de critério, formando conjuntos. Neste agrupamento, o que determina a adequação de um objeto ao conjunto será a distância entre os objetos da massa de dados.

No entanto, a utilidade de abordagens de re-ranqueamento para sistemas CBIR depende não apenas da eficácia, mas também da eficiência e escalabilidade. Enquanto a eficácia está relacionada à qualidade das imagens recuperadas, a eficiência se refere ao tempo gasto para obter os resultados. A escalabilidade considera a capacidade do sistema de lidar com coleções de imagens que são constantemente alimentadas. Visando computar a relação entre as imagens, algoritmos de re-ranqueamento muitas vezes consideram todas as distâncias entre as imagens de um determinado conjunto de dados, que representam um grande esforço computacional (normalmente, entre  $O(N^2)$  e  $O(N^3)$ ), dificultando seu uso em serviços de busca que lidam com coleções de imagens do mundo real.

Algoritmos para pesquisar em espaços métricos podem ser divididos em duas grandes áreas: métodos baseados em pivôs e baseados em clusterização. Um método que usa um pivô como estratégia seleciona alguns objetos como pivôs da coleção e, em seguida, calcula e armazena as distâncias entre os pivôs e os objetos da base de dados. Durante a busca, essas distâncias são usadas para descartar objetos sem compará-los com a consulta (GUIMARÃES PEDRONETTE; ALMEIDA; DA S. TORRES, 2014). As técnicas de agrupamento consistem em dividir o espaço em zonas tão compactas quanto possível, normalmente de forma recursiva, e

armazenar um representante ("centro") para cada zona mais alguns dados extras que nos permitem descartar rapidamente a zona no momento da consulta. Em uma pesquisa, regiões completas são descartadas usando as distâncias de seus representantes para a consulta.

### 2.7.1 Definição do problema

endo  $C = \{img_1, img_2, \dots, img_N\}$  uma base de imagens, onde  $N$  é a cardinalidade  $|C|$  da coleção  $C$ . Sendo  $D$  um descritor no qual pode ser definido como uma tupla  $(\epsilon, \rho)$ , onde:

- $\epsilon : I \rightarrow \mathbb{R}^n$  é uma função que extrai um vetor de características  $v_I$  de uma imagem  $I$
- $\rho : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função de distância que computa a distância entre duas imagens pela média de seus vetores de características correspondentes

Para obter a distância entre duas imagens  $img_i$  e  $img_j$  é necessário calcular o valor de  $\rho(\epsilon(img_i), \epsilon(img_j))$ . Para fins de legibilidade, e simplicidade, a notação  $\rho(img_i, (img_j))$  será usada para denotar a distância entre as imagens  $img_i$  e  $img_j$ .

Baseado na distância de função  $\epsilon$ , dada uma imagem de consulta  $img_q$ , nós podemos computar uma lista ranqueada  $\sigma_q$  como resposta da consulta. As listas ranqueadas podem conter informações da distância de uma coleção inteira. Contudo, espera-se que nas posições mais acima da lista estejam contidas as imagens mais relevantes à imagem de consulta. Dessa maneira, é desejável que a lista ranqueada  $\sigma_q$  considere apenas um subconjunto das  $N_s$  imagens mais similares, onde  $N_s < N$  é o número de imagens nas posições mais cima da lista que devemos considerar. É válido especialmente para coleções maiores, onde  $N$  é extremamente grande, e  $\sigma_q$  exige um esforço computacional altíssimo.

Desta maneira, a lista ranqueada  $\sigma_q = (img_1, img_2, \dots, img_{N_s})$  pode ser definida como uma permutação da coleção de imagens  $C_s \subset C$ , a qual contém as imagens mais similares à imagem consultada  $img_q$ , de tal modo que  $|C_s| = N_s$ . A permutação  $\sigma_q$  é uma bijeção da coleção  $C_s$  no conjunto  $[N_s] = \{1, 2, \dots, N_s\}$ . Para a permutação  $\sigma_q$  interpretamos  $\sigma_q(i)$  como a posição, ou rank, da imagem na lista  $\sigma_q$ . Desta forma, nós podemos dizer que, se  $img_x$  é ranqueada antes de  $img_y$ , ou seja,  $\sigma_q(x) < \sigma_q(y)$ , então  $\rho(img_q, img_x) < \rho(img_q, img_y)$ . Nós também podemos pegar cada  $img_i \in C$  como uma consulta de imagem  $img_q$ , a fim de obter um conjunto  $R = \{\sigma_1, \sigma_2, \dots, \sigma_N\}$  de listas ranqueadas para cada imagem da coleção  $C$ . Um algoritmo de re-ranqueamento de imagem é dado por uma função  $f_r$ , a qual recebe um

conjunto de listas ranqueadas  $R$  como entrada e gera um novo e mais efetivo conjunto de listas  $\hat{R}$ :

$$\hat{R} = f_r(R). \quad (2.1)$$

### 2.7.2 Técnicas para re-ranqueamento de imagens

Dentre os algoritmos que serão apresentados aqui, o primeiro irá servir para representar a implementação da função  $f_r$ . Este algoritmo explora a rica informação contextual codificada em listas de classificação, tendo como objetivo melhorar a eficácia de sistemas CBIR. O algoritmo é baseado em uma estratégia não supervisionada recentemente proposta (PEDRONETTE; DA S. TORRES, 2013) que calcula iterativamente a similaridade das “melhores”  $k$ -listas. A principal novidade desta abordagem consiste no uso de um subconjunto das listas classificadas, ao invés de usar a matriz de distância completa, e estruturas de indexação para computá-las, o que permite o uso do algoritmo em grandes coleções. Ou seja, ao invés de usar as informações de distância, o método proposto requer apenas as informações de ranking. A ideia por trás deste algoritmo de reclassificação de imagem está na dependência da conjectura de que as informações contextuais codificadas na semelhança entre listas classificadas podem fornecer informações úteis para melhorar a eficácia de descritores CBIR. Em geral, se duas imagens são semelhantes, suas listas ranqueadas também devem ser semelhantes (PEDRONETTE; SILVA TORRES, 2010). É de alguma forma próximo à hipótese de cluster (BLAIR, 1979), que afirma que “documentos intimamente associados tendem a ser relevantes aos mesmos pedidos”.

Uma vez que existem vários descritores de imagem disponíveis e cada um usa diferentes abordagens para cálculo de distância, pontuações calculadas por diferentes descritores de imagem geralmente estão em escalas diferentes e requerem procedimentos de normalização. Essas variações podem afetar a eficácia das abordagens de reclassificação. Por outro lado, até mesmo abordagens diferentes para o cálculo da distância produzem listas classificadas com a mesma estrutura.

## 2.8 Algoritmo RL-Sim

O algoritmo RL-Sim (PEDRONETTE; TORRES et al., 2013) é um método de aprendizado não-supervisionado, fazendo com o que o programa aprenda por conta própria, sem qualquer tipo

de dado rotulado. Esse algoritmo funciona através do método de *re-ranking*, onde um processo de reclassificação iterativa gera uma nova lista ranqueada, com uma qualidade melhor, e que será usada para gerar uma nova lista, até o fim do programa. Um dos pontos deste algoritmo é o fato dele utilizar informações contextuais vindas das próprias listas.

A ideia central do algoritmo está na proposição de que quanto maior a posição na lista ranqueada maior é a similaridade entre as imagens da mesma. Ou seja, as imagens mais ao topo de uma lista ranqueada *top-k* terão maior similaridade do que as do fundo.

Com base nessa premissa, o RL-Sim utiliza informações contextuais vindas das próprias listas para melhorar a qualidade dos resultados. O processo de re-ranking iterativo gera uma nova lista ranqueada com uma qualidade melhor em comparação com a lista anterior, utilizando critérios de classificação que levam em consideração a similaridade entre as imagens e as preferências do usuário.

Além disso, o RL-Sim também pode ser utilizado para processar imagens em grandes conjuntos de dados, como bancos de imagens ou galerias de arte. Nesses casos, o algoritmo pode aprender a partir das interações do usuário com as imagens e gerar listas ranqueadas personalizadas com base em suas preferências. O algoritmo RL-Sim é um método inovador de aprendizado não supervisionado que pode ser aplicado ao processamento de imagens, permitindo que o programa aprenda por conta própria e gere listas ranqueadas mais precisas e relevantes com base nas preferências do usuário e informações contextuais vindas das próprias listas.

### 2.8.1 Descrição matemática

O algoritmo RL-Sim leva como entrada um conjunto inicial de listas ranqueadas  $R$ , dada pelo conjunto  $R = \{R_1, R_2, \dots, R_n\}$ , onde  $\{R_1, R_2, \dots, R_n\}$  é um conjunto de listas ranqueadas. Cada lista ranqueada deste conjunto é formada por  $N$  imagens. Este conjunto é formado a partir do cálculo entre a imagem consultada e uma matriz de distância  $M$ . Essa matriz surge do cálculo da distância entre as imagens usando como base algum descritor, que define uma função de distância para isto.

Após formado o conjunto inicial de listas ranqueadas  $R$ , uma função de similaridade  $\psi$  é utilizada para gerar uma matriz de distância  $\hat{M}$ , sendo está mais eficaz que a anterior. Podemos definir  $\psi$  como:  $R \times R \times \mathbb{N}$ . Além de gerar uma nova matriz de distância, este re-ranqueamento irá gerar um novo conjunto de listas ranqueadas  $\hat{R}$ . Este ciclo se repete até o fim da última

iteração, onde espera-se a melhor lista ranqueada possível. Uma demonstração do algoritmo (PEDRONETTE; TORRES et al., 2013), em inglês, é representada na figura 2.7:

---

**Algorithm 1** RL-Sim Re-Ranking Algorithm [11]

---

**Require:** Original set of ranked lists  $\mathcal{R}$ , distance matrix  $A$ ,  
and parameters  $K_s, T, \lambda$

**Ensure:** Processed set of ranked lists  $\hat{\mathcal{R}}$

- 1:  $t \leftarrow 0$
- 2:  $\mathcal{R}_t \leftarrow \mathcal{R}$
- 3:  $A_t \leftarrow A$
- 4:  $K \leftarrow K_s$
- 5: **while**  $t < T$  **do**
- 6:   **for all**  $R_i \in \mathcal{R}_t$  **do**
- 7:      $c \leftarrow 0$
- 8:     **for all**  $img_j \in R_i$  **do**
- 9:       **if**  $c \leq \lambda$  **then**
- 10:           $A_{t+1}[i, j] \leftarrow 1/(1 + \psi(R_i, R_j, K))$
- 11:       **else**
- 12:           $A_{t+1}[i, j] \leftarrow 1 + A_t[i, j]$
- 13:       **end if**
- 14:      $c \leftarrow c + 1$
- 15:   **end for**
- 16: **end for**
- 17:  $A_{t+1} \leftarrow \text{normalization}(A_{t+1})$
- 18:  $\mathcal{R}_{t+1} \leftarrow \text{per fom ReRanking}(A_{t+1})$
- 19:  $t \leftarrow t + 1$
- 20:  $K \leftarrow K + 1$
- 21: **end while**
- 22:  $\hat{\mathcal{R}} \leftarrow \mathcal{R}_T$

---

Figura 2.7: Algoritmo de re-ranqueamento do RL-Sim. Fonte: (PEDRONETTE; TORRES et al., 2013).

# Capítulo 3

## Método proposto

Neste capítulo a metodologia utilizada no trabalho é apresentada, trazendo também todos os materiais e meios empregados para a realização do projeto.

### 3.1 Materiais e Métodos

A finalidade desta seção é abordar a metodologia e os recursos utilizados neste projeto. O foco do trabalho está na aplicação de um método de aprendizado não-supervisionado utilizando um conjunto de listas ranqueadas, estas que são geradas de um *dataset* de imagens pulmonares. Para isso, este *dataset* passará por um pré-processamento, onde as imagens serão aprimoradas e, logo em seguida, um descritor será selecionado para fazer a extração de características das imagens, incluindo a de consulta. Essas características serão armazenadas em um vetor correspondente, um para a imagem de consulta e outro para as imagens do *dataset*. Feita a separação, uma função de distância será empregada para calcular a distância entre as características. O retorno é então salvo e ordenado de acordo com a similaridade: as imagens mais próximas da consultada serão o topo da lista ranqueada.

Após essa etapa, executamos o algoritmo de aprendizado não-supervisionado RL-Sim com o objetivo de aumentar a eficácia da recuperação no auxílio ao diagnóstico. A figura 3.1 ilustra o procedimento completo.

#### 3.1.1 Objetivos

O presente trabalho tem como objetivo principal:

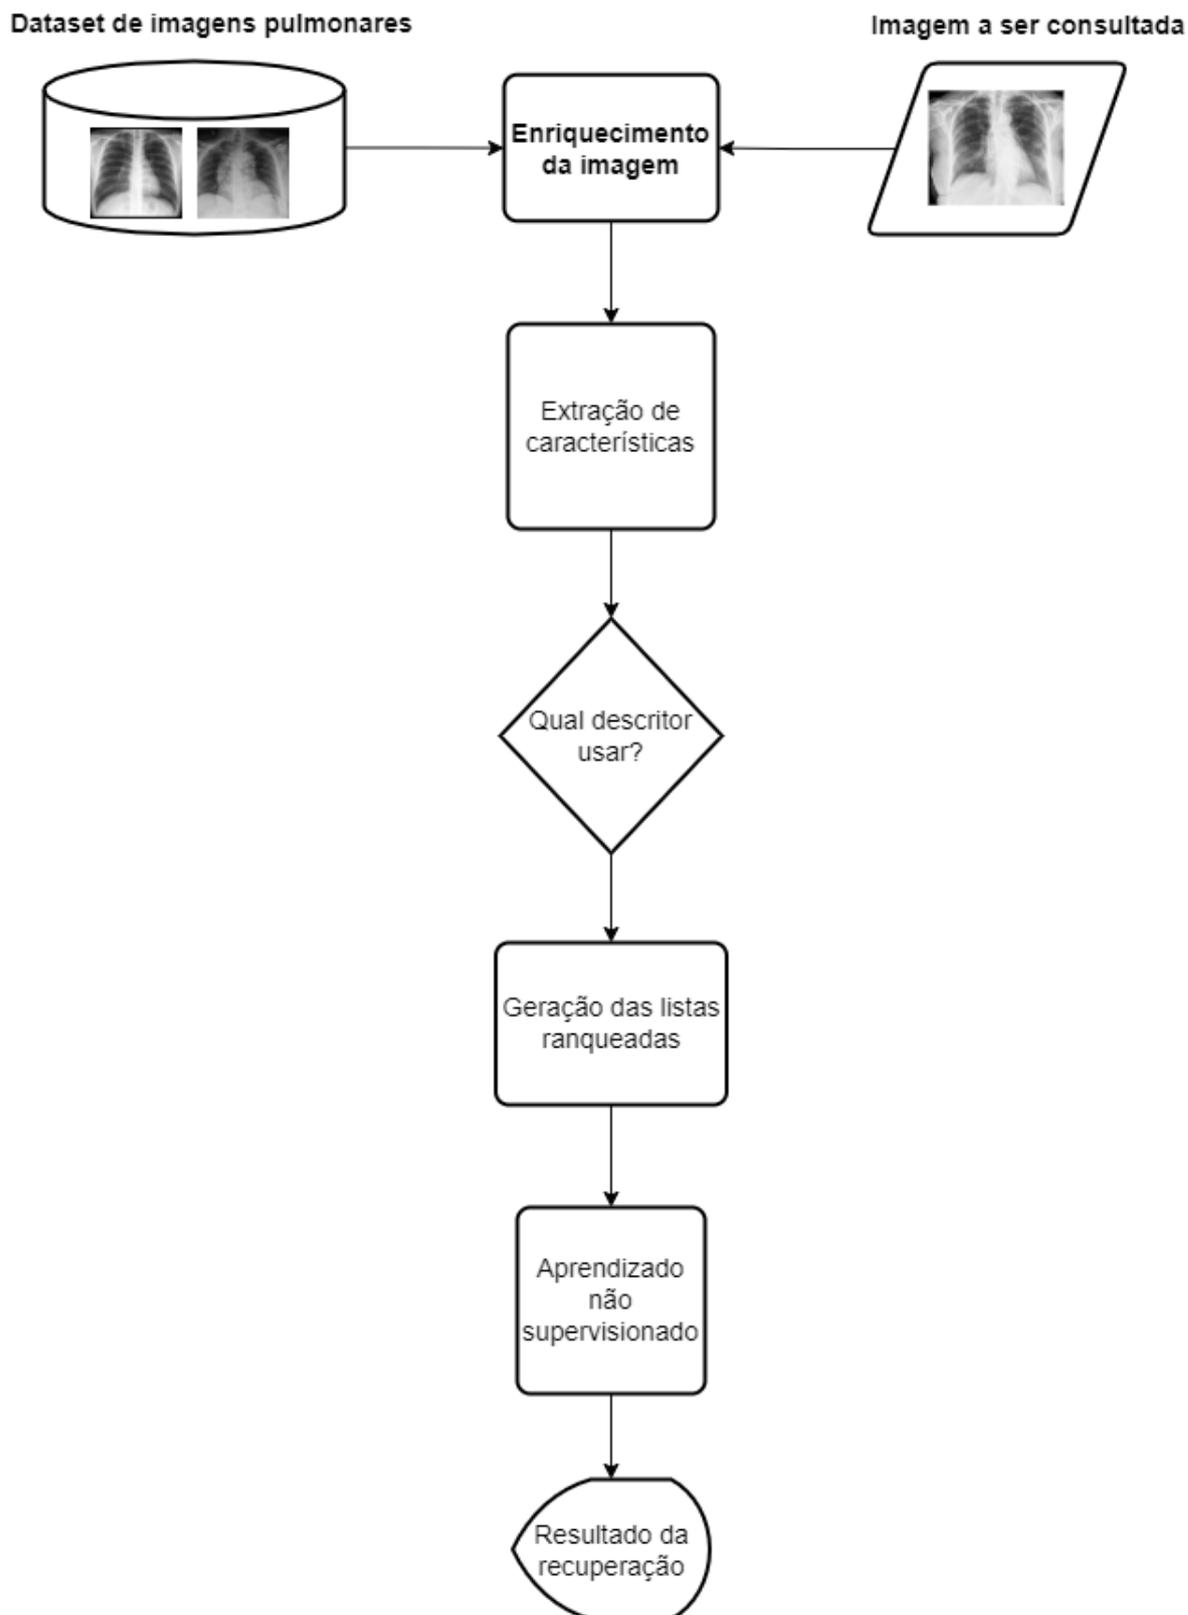


Figura 3.1: Fluxograma da metodologia proposta

- A utilização de um *dataset*(RAHMAN et al., 2021) de raios X de pulmão, onde as imagens serão pré-processadas utilizando-se alguma técnica de processamento digital de imagem.

- Busca acerca de descritores aplicáveis e definição do(s) descrito(res)
- Escolha de uma função de distância atrelada ao(s) descritor(es)
- Realização do processo de ranqueamento das imagens
- Aplicação do algoritmo de aprendizado não-supervisionado RL-Sim
- Avaliação dos resultados e desenvolvimento da monografia
- Refinamento da monografia para avaliação final

### 3.1.2 Dataset utilizado

A base de dados escolhida para o projeto foi desenvolvida por um time de pesquisadores e está sendo disponibilizada gratuitamente para fins acadêmicos.<sup>1</sup>A base é ativa e recebe novas inserções de imagens para consulta a cada nova atualização. O *dataset* possui 33.920 imagens de COVID-19: 10.701 imagens de pulmões normais, 11.263 imagens de infecções pulmonares que não são Covid-19 e, por fim, 11.956 imagens de pulmões acometidos pela Covid-19.

### 3.1.3 Descritores utilizados

Parte do desenvolvimento do trabalho consiste na identificação e seleção de descritores apropriados para o suporte ao diagnóstico de pulmões acometidos pela Covid-19. O critério de escolha dos descritores foi baseado na necessidade de trabalhar os níveis de cinza das imagens selecionadas.

#### LBP

O descritor LBP (Local Binary Patterns) é uma técnica de processamento de imagem amplamente utilizada para extração de características locais de uma imagem. Ele foi proposto por Ojala et al. em 1994 e desde então tem sido aplicado com sucesso em diversas tarefas de visão computacional, como reconhecimento de faces, detecção de texturas, classificação de objetos, entre outros. O LBP opera em imagens digitais em escala de cinza, analisando localmente cada pixel e seus vizinhos. Para cada pixel de interesse, o LBP compara o valor do pixel central com os valores dos pixels vizinhos. A comparação é feita

---

<sup>1</sup>Dataset das imagens de Covid-19: <https://www.kaggle.com/datasets/anasmohammedtahir/covidqu>

utilizando uma estratégia simples: cada vizinho é marcado com 1 se o seu valor for maior ou igual ao valor do pixel central, e com 0 caso contrário. Esses valores binários são então concatenados em uma sequência, formando o padrão binário local. Após a criação do padrão binário local, o LBP atribui a ele um valor decimal, tratando a sequência binária como um número binário e convertendo-o para sua representação decimal. Esse valor decimal representa o padrão local da região analisada. Para descrever uma imagem usando LBP, o processo é repetido para cada pixel, resultando em um mapa de características LBP que mostra o padrão local em cada ponto da imagem. Em seguida, um histograma é calculado a partir dos valores LBP para capturar a distribuição desses padrões na imagem. Esse histograma LBP pode ser usado como um vetor de características para treinar classificadores ou realizar outras tarefas de processamento de imagem. O LBP possui várias variantes e extensões, como o LBP uniforme, o LBP rotoinvariante e o LBP em escala invariante. Essas variantes foram desenvolvidas para melhorar a robustez do descritor em relação a variações de iluminação, rotação e escala. O descritor LBP é uma técnica de processamento de imagem que extrai informações locais de uma imagem por meio da comparação dos valores dos pixels e seus vizinhos. Ele é amplamente utilizado em várias aplicações de visão computacional devido à sua simplicidade, eficiência e capacidade de capturar características relevantes da imagem.

### **GLCM**

GLCM significa "Matriz de Coocorrência de Níveis de Cinza", (Em inglês, Gray-Level Co-occurrence Matrix). É uma técnica usada para análise de texturas em imagens digitais. A GLCM é uma matriz que descreve a frequência de ocorrência de diferentes combinações de níveis de cinza em uma imagem. A GLCM é calculada com base na distribuição espacial dos valores de intensidade dos pixels na imagem. Ela mede a relação entre um pixel e seus pixels vizinhos em uma determinada direção, capturando informações sobre a textura da imagem. A matriz resultante descreve a probabilidade de encontrar um par de valores de intensidade de pixels específicos em uma determinada distância e direção na imagem. A GLCM pode ser usada para extrair diversas informações texturais de uma imagem, como contraste, homogeneidade, energia e correlação. Essas medidas podem ser usadas para caracterizar e classificar diferentes tipos de texturas presentes na imagem. A análise de texturas usando a GLCM é amplamente utilizada em áreas como processamento de imagens, visão

computacional, reconhecimento de padrões e análise de imagens médicas. Ela fornece informações valiosas sobre a estrutura e as propriedades das texturas presentes nas imagens, sendo aplicada em uma variedade de aplicações, como detecção de falhas em materiais, classificação de objetos e diagnóstico médico.

### **Histograma de intensidade**

O descritor de histograma é uma técnica utilizada em processamento de imagens e visão computacional para representar uma imagem ou uma região de interesse por meio da distribuição dos valores de intensidade dos pixels. Essa representação é feita por um histograma, que é uma contagem do número de pixels em cada intervalo de intensidade. O processo de criação de um descritor de histograma envolve os seguintes passos:

1. → Converter a imagem para escala de cinza, se necessário, para simplificar análise dos valores de intensidade.
2. → Dividir o intervalo de intensidade em um número fixo de intervalos ou bins.
3. → Contar o número de pixels que possuem valores de intensidade em cada um dos bin
4. → Contar o número de pixels que possuem valores de intensidade em cada um dos bin
5. → Normalizar os valores contados, de modo que a soma de todos os valores do histograma seja igual a 1 ou 100
6. → O descritor de histograma final é a representação dos valores normalizados do histograma.

O descritor de histograma é frequentemente utilizado como uma forma compacta de representar a informação de cor ou textura de uma imagem. Pode ser utilizado em diversas aplicações, tais como classificação de objetos, reconhecimento de padrões, detecção de anomalias e recuperação de imagens por conteúdo. Ao comparar dois descritores de histograma, é comum utilizar medidas de similaridade, como a distância euclidiana ou a correlação, para avaliar o quão parecidos são os histogramas e, por consequência, as imagens que eles representam. É importante ressaltar que existem variações e melhorias do descritor de histograma, como a utilização de histogramas bidimensionais ou a inclusão de informações espaciais, dependendo da aplicação específica.

### 3.1.4 UDLF

O Unsupervised Distance Learning Framework (UDLF) é um framework de aprendizado não supervisionado (VALEM; PEDRONETTE, 2017) que visa extrair informações significativas e relevantes de conjuntos de dados não rotulados. Essa abordagem é particularmente útil quando não temos acesso a rótulos ou quando rotular os dados é caro ou inviável. O UDLF foi utilizado para realizar a aplicação do algoritmo RL-Sim.

A principal ideia por trás do UDLF é aprender representações de dados que capturem as relações intrínsecas e as estruturas subjacentes presentes nos dados não rotulados. O objetivo é descobrir padrões e agrupamentos de maneira automática, sem depender de supervisão externa.

Existem várias técnicas e algoritmos que podem ser utilizados no contexto do UDLF. Alguns dos métodos comuns incluem:

- **Análise de Componentes Principais (PCA):** é uma técnica de redução de dimensionalidade que mapeia os dados para um espaço de menor dimensão, preservando a maior quantidade possível de variação dos dados originais. O PCA é frequentemente usado para identificar os componentes mais importantes dos dados e visualizar agrupamentos.
- **Agrupamento K-means:** é um algoritmo de aprendizado não supervisionado amplamente utilizado para particionar um conjunto de dados em grupos ou clusters. O objetivo do K-means é agrupar pontos de dados semelhantes em clusters, maximizando a similaridade intracluster e minimizando a similaridade intercluster.
- **Redes Neurais Autoencoder:** são redes neurais especializadas em comprimir e reconstruir dados. Eles consistem em uma camada de codificação que mapeia os dados para uma representação latente de dimensionalidade reduzida e uma camada de decodificação que reconstrói os dados originais a partir da representação latente. O treinamento de um autoencoder busca minimizar o erro de reconstrução, incentivando-o a aprender representações significativas.
- **Análise de Agrupamento Espectral:** é uma técnica que utiliza a matriz de similaridade dos dados para realizar o agrupamento. Ela explora as relações entre os pontos de dados e constrói uma matriz de similaridade, que é então usada para identificar os agrupamentos. Essa abordagem é especialmente útil quando os dados têm uma estrutura não linear.

Ele foi utilizado de forma a gerar os resultados das amostras dentro de um HTML. O framework define um modelo amplo, permitindo a implementação de diferentes métodos não supervisionados e suportando diversos formatos de arquivo para entrada e saída. As execuções e experimentos podem ser facilmente definidos configurando um arquivo de configuração. O framework também inclui a avaliação dos resultados de recuperação, exportando resultados visuais, calculando medidas de eficácia e eficiência. O código-fonte está disponível publicamente, para que qualquer pessoa possa acessar, usar, modificar e compartilhar o software sob os termos da licença GPLv2 .

Atualmente, onze diferentes métodos de aprendizado não supervisionado estão implementados: RFE, RDPAC, BFSTree, LHRR, ContextRR, Correlation Graph, CPRR, Rk Graph Dist., ReckNNGraph, RL-Recom e RL-Sim\* .

Para usar o UDLF, é necessário executar o binário do software no terminal. No Linux e MacOS: `./udlf [config.ini]` e no Windows: `call udlf.exe [config.ini]`. O arquivo de configuração especifica tudo sobre a execução: a tarefa desejada, o método utilizado, informações do conjunto de dados, arquivos de entrada e saída, configurações de avaliação e outros detalhes .

### 3.1.5 Enriquecimento da imagem

Esta etapa consiste em realizar o pré-processamento de todas as imagens. Ela é realizada antes da extração de características (CHOUDHARY et al., 2014) e tem como objetivo melhorar o aspecto da imagem, deixando ela mais entendível para um computador. Um exemplo, mostrado na figura 3.2 é a técnica de aprimoramento *Contrast Limited Adaptive Histogram Equalization* – CLAHE, que faz uso de um histograma para análise estatística das informações da imagem (SETIAWAN et al., 2013).

### 3.1.6 Extração de características

Como descrito na seção 2.4, um descritor extrai as características das imagens através de alguma função matemática e armazena-as em um vetor de características. Após isso as imagens passam por um cálculo de distância a fim de gerar as listas ranqueadas.

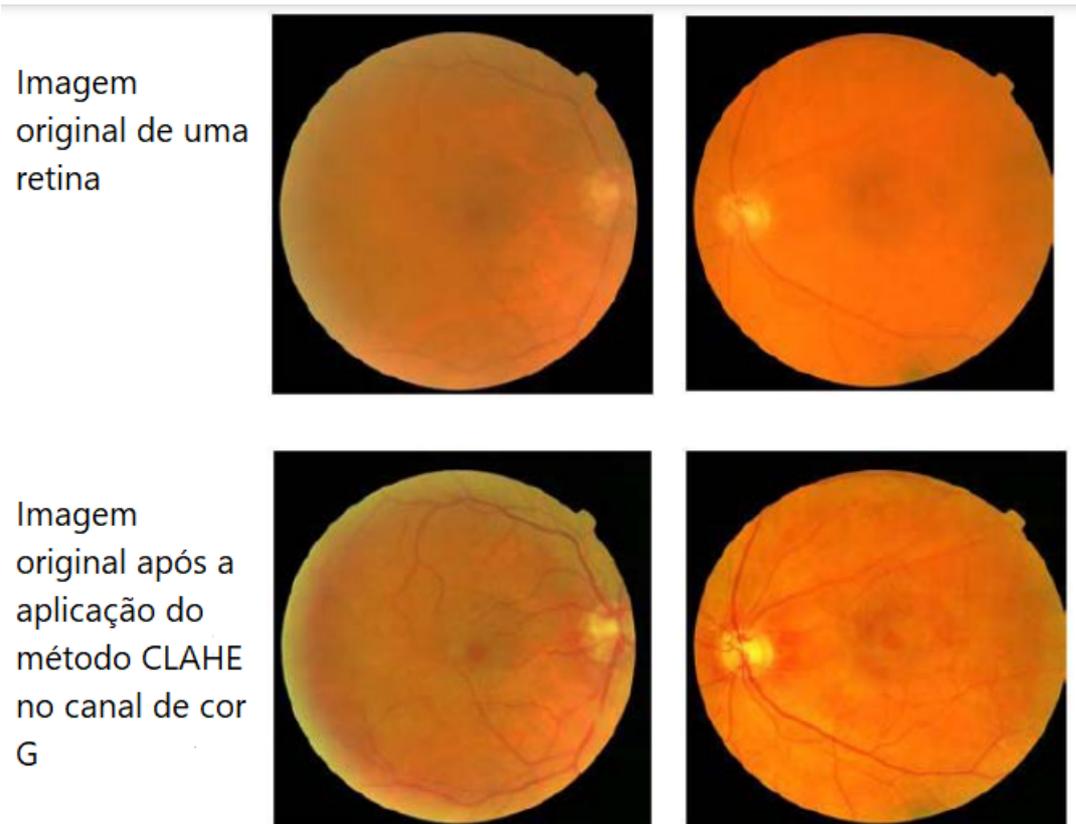


Figura 3.2: Aplicação da técnica de aprimoramento de imagens CLAHE. Fonte: (SETIAWAN et al., 2013)

### 3.1.7 Aprendizado Não-Supervisionado

Nesta etapa de pós-processamento dos dados tratados, o objetivo é alcançar um resultado final aprimorado por meio do método de aprendizado não supervisionado denominado RL-Sim. O RL-Sim é um processo iterativo de reclassificação, no qual cada iteração gera novas classificações com base nas classificações anteriores.

O processo de reclassificação iterativa permite que o modelo aprenda e refine sua compreensão dos dados ao longo do tempo. A cada iteração, o modelo analisa as reclassificações anteriores, identifica padrões e tendências e utiliza essas informações para gerar novas classificações mais precisas.

Essa abordagem iterativa é especialmente útil em cenários onde os dados são complexos ou ambíguos, e uma única classificação não é suficiente para capturar todas as nuances e características relevantes. Ao realizar várias iterações de reclassificação, o modelo pode considerar diferentes perspectivas e contextos, melhorando gradualmente sua capacidade de classificação.

O processo de reclassificação iterativa também permite que o modelo aproveite o feedback humano durante as iterações. Especialistas podem revisar e validar as classificações geradas pelo modelo, identificar erros ou inconsistências e fornecer orientações adicionais. Essa interação entre o modelo e os especialistas humanos contribui para um resultado final mais preciso e confiável.

Ao final das iterações de reclassificação, espera-se obter um conjunto de classificações refinadas e mais precisas em relação às classificações iniciais. Essas classificações podem ser utilizadas para diversos fins, como segmentação de dados, identificação de padrões, personalização de recomendações ou qualquer outra tarefa relacionada ao processamento de dados.

O uso do método de aprendizado não supervisionado RL-Sim, por meio do processo de reclassificação iterativa na etapa de pós-processamento dos dados tratados, busca aprimorar o resultado final, permitindo ao modelo aprender e se adaptar com base nas iterações anteriores e no feedback humano. Essa abordagem contribui para uma compreensão mais refinada dos dados e promove a obtenção de resultados mais precisos e confiáveis

### 3.1.8 Uso da Linguagem Python

O Python é uma linguagem de programação de alto nível, interpretada e de propósito geral. Ela foi criada por Guido van Rossum e lançada pela primeira vez em 1991. Desde então, o Python ganhou popularidade significativa devido à sua sintaxe limpa e legível, suporte a múltiplos paradigmas de programação e uma vasta biblioteca padrão. Além disso, a comunidade Python é muito ativa e desenvolveu uma ampla gama de bibliotecas de terceiros, tornando-a uma escolha popular para uma variedade de aplicações.

Uma das vantagens do Python é sua facilidade de uso e aprendizado. Sua sintaxe é intuitiva e legível, o que o torna uma ótima opção para iniciantes em programação. Além disso, o Python é uma linguagem interpretada, o que significa que você pode escrever, testar e depurar seu código de forma interativa, facilitando o processo de desenvolvimento.

No campo do processamento de imagens e visão computacional, o Python é amplamente utilizado devido à sua capacidade de lidar com bibliotecas poderosas, como OpenCV e scikit-image. Essas bibliotecas fornecem funções e algoritmos para análise de imagens, processamento de pixels e extração de recursos, como descritores GLCM (Matriz de Coocorrência de Nível de Cinza), LBP (Local Binary Patterns) e histograma.

O descritor GLCM é usado para capturar informações sobre a distribuição espacial das intensidades de níveis de cinza em uma imagem. Ele calcula a matriz de coocorrência de níveis de cinza, que representa a frequência com que pares de intensidades de níveis de cinza ocorrem em uma determinada direção e distância. O Python, com suas bibliotecas de processamento de imagens, oferece métodos eficientes para calcular e extrair essas informações da imagem.

O LBP é outro descritor comumente usado em visão computacional para análise de textura. Ele extrai informações sobre a distribuição de padrões locais de pixels em uma imagem. O Python permite implementar facilmente algoritmos LBP e aplicá-los a imagens para extrair características úteis.

O histograma é uma representação gráfica da distribuição de intensidades de pixels em uma imagem. Ele mostra a quantidade de pixels em diferentes faixas de intensidade. O histograma é amplamente utilizado em processamento de imagens para análise e extração de recursos. O Python fornece bibliotecas para calcular histogramas de imagens e realizar operações estatísticas sobre eles.

Em suma, Python é uma linguagem de programação versátil e de fácil uso, o que o torna uma escolha popular para processamento de imagens e visão computacional. Sua vasta biblioteca padrão e bibliotecas de terceiros oferecem recursos poderosos para calcular e extrair descritores como GLCM, LBP e histograma, permitindo a análise eficiente de imagens e a extração de características relevantes para várias aplicações nesse campo.

# Capítulo 4

## Resultados

O presente capítulo visa apresentar os resultados obtidos a partir da execução da metodologia proposta no capítulo anterior. Os experimentos realizados são abordados na Seção 4.1, sendo descrita a implementação do código desenvolvido. A Seção 4.2 apresenta e discute os resultados obtidos para o algoritmo RL-Sim antes e depois da aplicação de descritores.

### 4.1 Desenvolvimento do código

Neste trabalho, a solução proposta é implementada utilizando a framework UDLF (*Unsupervised Deep Learning Framework*), que oferece suporte a diversos métodos de aprendizado não supervisionado para o ranqueamento de imagens.

Inicialmente, foram criados três scripts python, um para cada descritor: `HIST.py`, `GLCM_v2.py` e `LBP_v2.py`. Esses scripts seguem a mesma estrutura, diferenciando-se apenas no método utilizado para o cálculo do descritor. Abaixo, apresentamos um exemplo de cada caso:

#### **HISTOGRAMA DE INTENSIDADES**

```
def calculate_histogram(image):  
    image = (image * 255).astype(np.uint8)  
  
    % Calcular o histograma de intensidades  
    histogram = np.histogram(image, bins=256, range=(0, 255))[0]  
    return histogram
```

#### **GLCM**

```
def glcm_desc(imagem):  
    % Converte a imagem para byte, todas já são em tons de cinza  
    imagem_cinza = img_as_ubyte(imagem)  
  
    % Calcula o descritor GLCM  
    glcm = graycomatrix(imagem_cinza, [1], [0], levels=256, normed=True)  
  
    % Extrai as estatísticas do descritor GLCM  
    contraste = feature.graycoprops(glcm, 'contrast')[0, 0]  
    correlacao = feature.graycoprops(glcm, 'correlation')[0, 0]  
    energia = feature.graycoprops(glcm, 'energy')[0, 0]  
    homogeneidade = feature.graycoprops(glcm, 'homogeneity')[0, 0]  
  
    % Retorna as estatísticas como um vetor unidimensional  
    return np.array([contraste, correlacao, energia, homogeneidade])
```

## LBP

```
def calcular_lbp(imagem):  
    imagem = img_as_ubyte(imagem)  
    lbp = feature.local_binary_pattern(imagem, 8, 1, method='uniform')  
    hist, _ = np.histogram(lbp.ravel(), bins=np.arange(0, 60), range=(0, 59))  
    hist = hist.astype("float")  
    hist /= (hist.sum() + 1e-7)  
  
    return hist
```

Após a criação das funções, foram geradas as listas ranqueadas. Para ordená-las, utilizamos um cálculo de similaridade com a imagem de referência (primeira imagem da lista), aplicando a fórmula `np.linalg.norm(descritor - imagem_referencia)`. Esse processo foi repetido para todas as imagens do banco, alterando a imagem de referência a cada execução. Ao final desse procedimento, obtemos uma matriz quadrada semelhante a esta:

Normal(1).jpg Normal(3).jpg Normal(2).jpg  
Normal(2).jpg Normal(3).jpg Covid(2).jpg  
Covid(1).jpg Covid(3).jpg Nomal(1).jpg

Posteriormente, a framework UDLF foi utilizada para processar a matriz de entrada, que consiste em várias listas ranqueadas. Utilizamos o algoritmo de Re-ranqueamento RL-Sim fornecido pela UDLF para gerar uma nova matriz com o ranqueamento atualizado.

### 4.1.1 Cálculo de Precisão

Para calcular a precisão dos descritores GLCM (Matriz de Coocorrência de Níveis de Cinza), LBP (Local Binary Patterns) e Histograma, é necessário seguir algumas etapas específicas.

No caso do GLCM, primeiro é preciso extrair a matriz de coocorrência de níveis de cinza a partir da imagem de interesse. Essa matriz descreve as relações espaciais entre os níveis de cinza dos pixels. Em seguida, é possível calcular estatísticas relevantes, como contraste, correlação, energia e homogeneidade, a partir dessa matriz.

No LBP, o processo envolve a extração dos padrões binários locais para cada pixel da imagem. Em seguida, é possível calcular características dos padrões LBP, como histogramas ou estatísticas texturais.

Quanto ao Histograma, o cálculo da precisão envolve a criação do histograma da imagem, que representa a distribuição das intensidades de cores ou tons de cinza presentes na imagem. É possível calcular diferentes métricas a partir desse histograma, dependendo do contexto da aplicação.

Após a extração dos descritores (GLCM, LBP ou Histograma), é necessário ter um conjunto de dados de referência com rótulos corretos, ou seja, imagens que foram previamente classificadas corretamente. Com esse conjunto de referência, os valores dos descritores obtidos a partir das imagens de teste podem ser comparados com os valores de referência.

Finalmente, para avaliar a precisão dos descritores, é possível utilizar métricas comuns de avaliação, como acurácia, precisão, recall ou F1-score. Essas métricas fornecem uma medida do desempenho dos descritores em relação aos rótulos corretos, permitindo assim avaliar a qualidade e a precisão dos descritores GLCM, LBP e Histograma.

## 4.2 Métricas

De todos os descritores aplicados ao RL-Sim, o que apresentou o melhor resultado foi o Histograma de intensidade. Ficou visível um ganho maior em todas as amostras, como por exemplo aplicado ao P@4 e ao MAP.

Os resultados do experimento consistem da aplicação do algoritmo RL-Sim, descrito na Seção 2.8, com uma vizinhança fixa de  $k = 3$  para todos descritores. Fora isso, outras configurações usadas para o algoritmo foram o número de iterações fixo  $i = 3$  e a quantidade de imagens utilizadas de 1400, sendo 700 de pulmões saudáveis e 700 pulmões acometidos pela covid-19.

Podemos conferir os resultados obtidos na tabelas 4.1 e 4.2

Tabela 4.1: Tabela para P@4

Descritor	Tipo	Dataset	Score[%]	Métrica do RL-Sim	Ganhos
Histograma	Cor	Covid-19 Radiography Database	0.8825	0.8707	-13355%
LBP	Textura	Covid-19 Radiography Database	0.7939	0.7834	-13270%
GLCM	Textura	Covid-19 Radiography Database	0.6704	0.6737	0.5061%

Tabela 4.2: Tabela para o MAP

Descritor	Tipo	Dataset	Score[%]	Métrica do RL-Sim	Ganhos
Histograma	Cor	Covid-19 Radiography Database	0.5691	0.5798	18145%
LBP	Textura	Covid-19 Radiography Database	0.5901	0.5850	-0.8711%
GLCM	Textura	Covid-19 Radiography Database	0.5664	0.5726	1.0862%

Os resultados podem ser visualizados através de diversos formatos, dentre eles numérico, string, html ou todos estes (VALEM; PEDRONETTE, 2017). Na figura abaixo 4.1 temos um exemplo de exportação dos resultados no formato html gerado pelo UDLF, que extrai as informações e gera para nós importantes análises. Neste caso, a lista classificada, e ordenada, foi exportada como uma página, onde as imagens de consulta são destacadas com bordas verdes, enquanto os resultados incorretos são destacados com bordas vermelhas. A primeira linha representa os resultados originais da recuperação e a segunda linha representa os resultados após a execução do algoritmo.

Com base na análise da Figura 4.1, é possível constatar uma significativa melhoria na ordenação das imagens. Ao considerar a lista de entrada, observa-se que ocorreram duas classificações incorretas, porém, na lista de saída, nenhuma imagem foi erroneamente classificada. No entanto, é importante salientar que essa análise representa um estudo

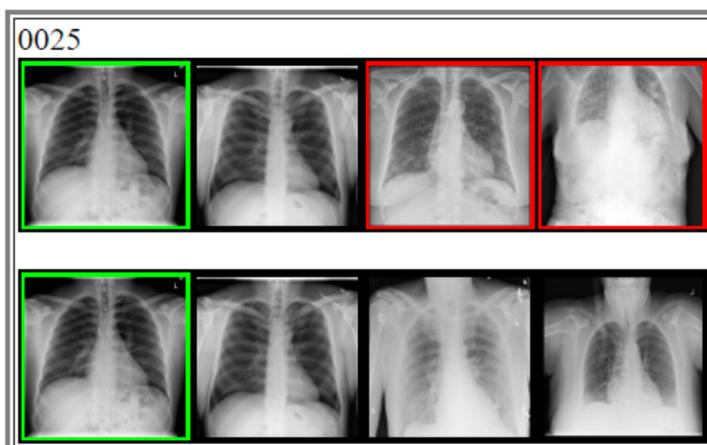


Figura 4.1: Algoritmo de re-ranqueamento do RL-Sim pós GLCM. Fonte: Autoria Própria.

específico e que a métrica de acurácia é fundamental para avaliar o desempenho dos descritores utilizados. Esse aspecto pode ser observado na Tabela 4.1 e 4.2, onde são apresentados os resultados correspondentes aos descritores LBP, GLCM e Histograma de Intensidades. Ao comparar o descritor GLCM com o LBP (Local Binary Patterns) e o histograma de intensidades, observou-se que o GLCM apresentou o desempenho mais limitado na detecção da COVID-19 em radiografias de tórax.

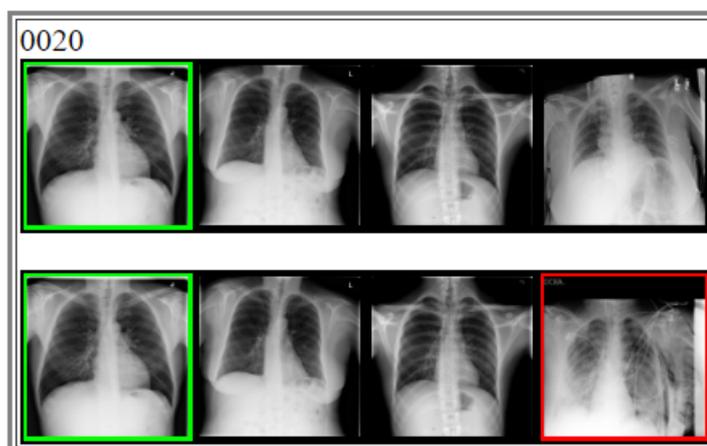


Figura 4.2: Algoritmo de re-ranqueamento do RL-Sim pós LBP. Fonte: Autoria Própria.

Na Figura 4.2, podemos observar um cenário oposto ao da figura anterior, caracterizado por uma deterioração na ordenação da lista classificada. Verifica-se que a utilização do algoritmo RL-Sim resultou em um caso classificado como COVID-19, embora fosse esperado um resultado de "normal".

Os resultados obtidos a partir da lista ranqueada utilizando o descritor LBP (Local Binary Patterns) para a detecção da COVID-19 em radiografias de tórax tanto para as primeiras 4 amostras na Tabela 4.1, quanto para o MAP na Tabela 4.2 revelaram algumas limitações em comparação ao uso do histograma de intensidades, por exemplo.

Embora o descritor LBP tenha sido capaz de detectar algumas áreas com padrões texturais anômalos, ele não foi tão eficaz quanto o histograma de intensidades em fornecer uma representação clara das opacidades pulmonares e áreas de inflamação, que são características distintas da COVID-19 em radiografias de tórax.

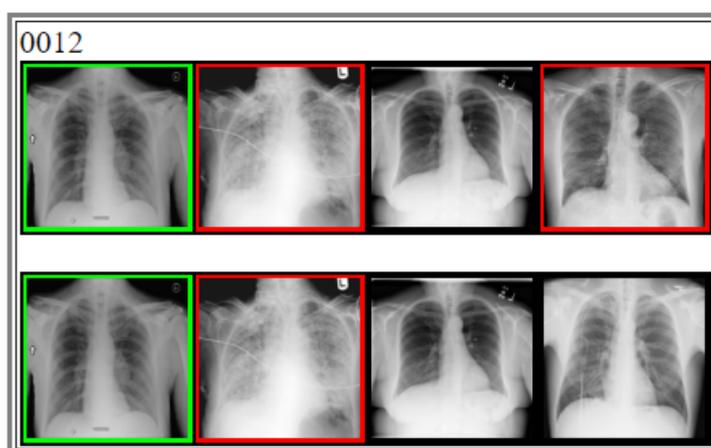


Figura 4.3: Algoritmo de re-ranqueamento do RL-Sim pós HIST. Fonte: Autoria Própria.

Com base na Figura 4.3, é possível constatar uma substancial melhoria no presente cenário, em que previamente ocorria a classificação equivocada de duas imagens. Atualmente, apenas uma imagem encontra-se discrepante em relação à imagem de referência, a qual representa um pulmão saudável.

O Histograma de intensidades se mostrou mais robusto na identificação dessas alterações, pois capturou diretamente as mudanças na intensidade de cinza nas áreas afetadas pelos pulmões infectados. Essas alterações foram visualmente perceptíveis como manchas mais claras ou mais escuras nas imagens radiográficas e puderam ser quantificadas por meio do histograma.

Ao analisar as radiografias, foi possível observar alterações significativas nos padrões de intensidade de cinza nas áreas dos pulmões afetadas pela infecção. Essas alterações se refletiram nos histogramas de intensidades, que apresentaram desvios em relação à distribuição esperada em radiografias de tórax saudáveis. A análise do histograma permitiu identificar padrões distintos relacionados à presença de opacidades pulmonares e áreas de

inflamação. As opacidades pulmonares foram visualmente observadas como manchas mais claras nas radiografias e se manifestaram como um deslocamento para a direita no histograma, indicando um aumento na intensidade de cinza. Por outro lado, as áreas de inflamação ou consolidação nos pulmões foram visualmente observadas como manchas mais escuras nas radiografias e se manifestaram como um deslocamento para a esquerda no histograma, indicando uma diminuição na intensidade de cinza.

Esses resultados indicam que o histograma de intensidades pode ser um recurso eficaz na detecção da COVID-19 em radiografias de tórax, proporcionando informações valiosas para auxiliar no diagnóstico e no monitoramento da doença. A análise do histograma permite uma abordagem objetiva e quantitativa, possibilitando a identificação de padrões específicos associados à infecção pelo SARS-CoV-2.

No entanto, é importante destacar que a interpretação dos resultados do histograma deve ser realizada por médicos especializados, levando em consideração outros critérios clínicos, epidemiológicos e laboratoriais para um diagnóstico completo e preciso da COVID-19.

Em suma, os resultados obtidos com a utilização do histograma de intensidades na lista ranqueada demonstraram a viabilidade desse recurso como uma ferramenta adicional na detecção da COVID-19 em radiografias de tórax, oferecendo suporte no diagnóstico e no acompanhamento dessa doença respiratória.

## Capítulo 5

### Considerações Finais

Em geral, na primeira etapa deste projeto inclui-se a procura e identificação de conceitos e informações fundamentais na área recuperação de imagem, tal como CBIR, ranqueamento, técnicas de ranqueamento, descritores, processamento digital de imagem e imageamento médico. Dentre as dificuldades encontradas durante o desenvolvimento da primeira parte do projeto, a identificação de um dataset relevante foi um dos desafios, tendo em vista a necessidade específica de imagens de raio-x do projeto proposto. Outra dificuldade reside no entendimento dos métodos de ranqueamento e a escolha de um método apropriado, uma vez que existem inúmeros trabalhos que abordam cada um de sua maneira os diversos tipos de métodos.

Em relação aos próximos passos, os pontos de maior atenção do projeto estarão concentrados na escolha de descritores e implementação do algoritmo escolhido, sendo estas etapas a que consumirão maior tempo de desenvolvimento. Um outro passo que é fundamental para o trabalho é o de escolha da métrica de distância que será utilizada no algoritmo RL-Sim, tendo em vista a diversidade de métricas disponíveis para uso. Esta etapa não deve exigir muito tempo, uma vez que essas métricas já existem, precisando apenas ser feita uma identificação e escolha. Um outro passo muito importante, e não mensurável, está na fase de testes do código, onde exige-se um esforço computacional muito grande para realizar todos cálculos necessários afim de obter uma lista ranqueada final.

Por fim, é importante ressaltar a interdisciplinaridade do projeto, que sintetiza áreas da medicina nuclear, visão computacional, processamento digital de imagem e sistemas de recuperação de imagem em uma coisa só. Fora isso, o tema é extremamente pertinente, tanto

no momento atual quanto em momentos futuros, onde a necessidade de um diagnóstico baseado em imagens é extremamente útil.

## Referências bibliográficas

AKGÜL, C. B. et al. Content-Based Image Retrieval in Radiology: Current Status and Future Directions. **Journal of Digital Imaging**, v. 24, n. 2, p. 208–222, abr. 2011. ISSN 1618-727X. DOI: 10.1007/s10278-010-9290-9. Disponível em: <<https://doi.org/10.1007/s10278-010-9290-9>>.

ALMEIDA, J.; ROCHA, A.; TORRES, R.; GOLDENSTEIN, S. Making Colors Worth More than a Thousand Words. In: PROCEEDINGS of the 2008 ACM Symposium on Applied Computing. Fortaleza, Ceara, Brazil: Association for Computing Machinery, 2008. (SAC '08), p. 1180–1186. ISBN 9781595937537. DOI: 10.1145/1363686.1363961. Disponível em: <<https://doi.org/10.1145/1363686.1363961>>.

ALSMADI, M. K. Content-Based Image Retrieval Using Color, Shape and Texture Descriptors and Features. **Arabian Journal for Science and Engineering**, v. 45, n. 4, p. 3317–3330, abr. 2020. ISSN 2191-4281. DOI: 10.1007/s13369-020-04384-y. Disponível em: <<https://doi.org/10.1007/s13369-020-04384-y>>.

ANALYTICSVIDHYA. **How Images are stored in the computer?** 2021. Disponível em: <<https://www.analyticsvidhya.com/blog/2021/03/grayscale-and-rgb-format-for-storing-images/>>. Acesso em: 12 nov. 2021.

ANDERSEN, K. G. et al. The proximal origin of SARS-CoV-2. **Nature Medicine**, v. 26, n. 4, p. 450–452, abr. 2020. ISSN 1546-170X. DOI: 10.1038/s41591-020-0820-9. Disponível em: <<https://doi.org/10.1038/s41591-020-0820-9>>.

APOSTOLOPOULOS, I. D.; MPESIANA, T. A. Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. **Physical and Engineering Sciences in Medicine**, v. 43, n. 2, p. 635–640, jun. 2020. ISSN 2662-4737. DOI: 10.1007/s13246-020-00865-4. Disponível em: <<https://doi.org/10.1007/s13246-020-00865-4>>.

BENMALEK, E.; ELMHAMDI, J.; JILBAB, A. Comparing CT scan and chest X-ray imaging for COVID-19 diagnosis. **Biomedical Engineering Advances**, v. 1, p. 100003, 2021. ISSN 2667-0992. DOI: <https://doi.org/10.1016/j.bea.2021.100003>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2667099221000037>>.

BLAIR, D. C. Information Retrieval, 2nd ed. C.J. Van Rijsbergen. London: Butterworths; 1979: 208 pp. Price: \$32.50. **Journal of the American Society for Information Science**, v. 30, n. 6, p. 374–375, 1979. DOI: <https://doi.org/10.1002/asi.4630300621>. eprint: <https://asistdl.onlinelibrary.wiley.com/doi/pdf/10.1002/asi.4630300621>. Disponível em: <<https://asistdl.onlinelibrary.wiley.com/doi/abs/10.1002/asi.4630300621>>.

CHOUDHARY, R. et al. An integrated approach to Content Based Image Retrieval. In: 2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI). [S.l.: s.n.], 2014. p. 2404–2410. DOI: 10.1109/ICACCI.2014.6968394.

COZZI, D. et al. Chest X-ray in new Coronavirus Disease 2019 (COVID-19) infection: findings and correlation with clinical outcome. **La radiologia medica**, v. 125, n. 8, p. 730–737, ago. 2020. ISSN 1826-6983. DOI: 10.1007/s11547-020-01232-9. Disponível em: <<https://doi.org/10.1007/s11547-020-01232-9>>.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. [S.l.]: Editora Blucher, 2000.

GUIMARÃES PEDRONETTE, D. C.; ALMEIDA, J.; DA S. TORRES, R. A scalable re-ranking method for content-based image retrieval. **Information Sciences**, v. 265, p. 91–104, 2014. ISSN 0020-0255. DOI: <https://doi.org/10.1016/j.ins.2013.12.030>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0020025513008864>>.

HATHCOCK, J. T.; STICKLE, R. L. Principles and Concepts of Computed Tomography. **Veterinary Clinics of North America: Small Animal Practice**, v. 23, n. 2, p. 399–415, 1993. ISSN 0195-5616. DOI: [https://doi.org/10.1016/S0195-5616\(93\)50034-7](https://doi.org/10.1016/S0195-5616(93)50034-7). Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0195561693500347>>.

HE, W.; ZHANG, Z. (; LI, W. Information technology solutions, challenges, and suggestions for tackling the COVID-19 pandemic. **International Journal of Information Management**, v. 57, p. 102287, 2021. ISSN 0268-4012. DOI: <https://doi.org/10.1016/j.ijinfomgt.2020.102287>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0268401220314869>>.

KUMAR, R. M.; SREEKUMAR, K. A survey on image feature descriptors. **Int J Comput Sci Inf Technol**, Citeseer, v. 5, p. 7668–7673, 2014.

LI, X.; WANG, X.; XIAO, G. A comparative study of rank aggregation methods for partial and top ranked lists in genomic applications. **Briefings in Bioinformatics**, v. 20, n. 1, p. 178–189, ago. 2017. ISSN 1477-4054. DOI: 10.1093/bib/bbx101. eprint: <https://academic.oup.com/bib/article-pdf/20/1/178/27689776/bbx101.pdf>. Disponível em: <<https://doi.org/10.1093/bib/bbx101>>.

LINGARAJ, H. Parallel Indexing on Color and Texture Feature Extraction using R-Tree for Content Based Image Retrieval. **International Journal of Computer Sciences and Engineering**, v. 3, p. 11–15, nov. 2015.

PEDRONETTE, D. C. G.; DA S. TORRES, R. Image re-ranking and rank aggregation based on similarity of ranked lists. **Pattern Recognition**, v. 46, n. 8, p. 2350–2360, 2013. ISSN 0031-3203. DOI: <https://doi.org/10.1016/j.patcog.2013.01.004>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S003132031300023X>>.

PEDRONETTE, D. C. G.; SILVA TORRES, R. da. Shape retrieval using contour features and distance optimization. In: CITESEER. VISAPP (2). [S.l.: s.n.], 2010. p. 197–202.

PEDRONETTE, D. C. G.; TORRES, R. d. S.; BORIN, E.; BRETERNITZ, M. Image Re-ranking Acceleration on GPUs. In: 2013 25th International Symposium on Computer Architecture and High Performance Computing. [S.l.: s.n.], 2013. p. 176–183. DOI: 10 . 1109 / SBAC - PAD . 2013 . 19.

PENATTI, O. A.; VALLE, E.; S. TORRES, R. da. Comparative study of global color and texture descriptors for web image retrieval. **Journal of Visual Communication and Image Representation**, v. 23, n. 2, p. 359–380, 2012. ISSN 1047-3203. DOI: <https://doi.org/10.1016/j.jvcir.2011.11.002>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1047320311001465>>.

PENATTI, O. A. B.; SILVA TORRES, R. da. Color descriptors for web image retrieval: a comparative study. In: IEEE. 2008 XXI Brazilian symposium on computer graphics and image processing. [S.l.: s.n.], 2008. p. 163–170.

PONTONE, G. et al. Role of computed tomography in COVID-19. **Journal of Cardiovascular Computed Tomography**, v. 15, n. 1, p. 27–36, 2021. ISSN 1934-5925. DOI: <https://doi.org/10.1016/j.jcct.2020.08.013>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1934592520304366>>.

RAHMAN, T. 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. ISSN 0010-4825. DOI: <https://doi.org/10.1016/j.combiomed.2021.104319>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S001048252100113X>>.

SETIAWAN, A. W.; MENGKO, T. R.; SANTOSO, O. S.; SUKSMONO, A. B. Color retinal image enhancement using CLAHE. In: INTERNATIONAL Conference on ICT for Smart Society. [S.l.: s.n.], 2013. p. 1–3. DOI: 10 . 1109 / ICTSS . 2013 . 6588092.

SHAKARAMI, A.; TARRAH, H. An efficient image descriptor for image classification and CBIR. **Optik**, v. 214, p. 164833, 2020. ISSN 0030-4026. DOI: <https://doi.org/10.1016/j.ijleo.2020.164833>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0030402620306690>>.

SIDDIQUIE, B.; FERIS, R. S.; DAVIS, L. S. Image ranking and retrieval based on multi-attribute queries. In: CVPR 2011. [S.l.: s.n.], 2011. p. 801–808. DOI: 10 . 1109 / CVPR . 2011 . 5995329.

TAMURA, H.; MORI, S.; YAMAWAKI, T. Textural Features Corresponding to Visual Perception. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 8, n. 6, p. 460–473, 1978. DOI: 10 . 1109 / TSMC . 1978 . 4309999.

VALEM, L. P.; PEDRONETTE, D. C. G. An Unsupervised Distance Learning Framework for Multimedia Retrieval. In: PROCEEDINGS of the 2017 ACM on International Conference on Multimedia Retrieval. Bucharest, Romania: ACM, 2017. (ICMR '17), p. 107–111. ISBN 978-1-4503-4701-3. DOI: 10 . 1145 / 3078971 . 3079017. Disponível em: <<http://doi.acm.org/10.1145/3078971.3079017>>.

WORLDOMETERS. **Coronavirus Cases**. 2021. Disponível em: <<https://www.worldometers.info/coronavirus/>>. Acesso em: 25 out. 2021.

YANG, S. et al. SkeletonNet: A Hybrid Network With a Skeleton-Embedding Process for Multi-View Image Representation Learning. **IEEE Transactions on Multimedia**, v. 21, n. 11, p. 2916–2929, 2019. DOI: 10.1109/TMM.2019.2912735.

YUE, J.; LI, Z.; LIU, L.; FU, Z. Content-based image retrieval using color and texture fused features. **Mathematical and Computer Modelling**, v. 54, n. 3, p. 1121–1127, 2011. *Mathematical and Computer Modeling in agriculture (CCTA 2010)*. ISSN 0895-7177. DOI: <https://doi.org/10.1016/j.mcm.2010.11.044>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0895717710005352>>.

YUKI, K.; FUJIOGI, M.; KOUTSOGIANNAKI, S. COVID-19 pathophysiology: A review. **Clinical Immunology**, v. 215, p. 108427, 2020. ISSN 1521-6616. DOI: <https://doi.org/10.1016/j.clim.2020.108427>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S152166162030262X>>.

ZHANG, X.; SMITH, N.; WEBB, A. 1 - Medical Imaging. In: FENG, D. D. (Ed.). **Biomedical Information Technology**. Burlington: Academic Press, 2008. (Biomedical Engineering). p. 3–27. ISBN 978-0-12-373583-6. DOI: <https://doi.org/10.1016/B978-012373583-6.50005-0>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780123735836500050>>.