

UNIVERSIDADE FEDERAL DE ALAGOAS  
PROGRAMA DE PÓS GRADUAÇÃO EM MODELAGEM COMPUTACIONAL DO  
CONHECIMENTO

YANA KELLEN DIOCLÉCIO MENDES

**MEDIDAS DE CENTRALIDADE PARA CLASSIFICAÇÃO AUTOMÁTICA DE  
DOENÇAS PULMONARES INTERSTICIAIS EM IMAGENS DE TOMOGRAFIA  
COMPUTADORIZADA**

Maceió-AL

Abril de 2019

YANA KELLEN DIOCLÉCIO MENDES

**MEDIDAS DE CENTRALIDADE PARA CLASSIFICAÇÃO AUTOMÁTICA DE  
DOENÇAS PULMONARES INTERSTICIAIS EM IMAGENS DE TOMOGRAFIA  
COMPUTADORIZADA**

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Computacional do Conhecimento da Universidade Federal de Alagoas como requisito necessário para à obtenção do título de Mestre em Modelagem Computacional do Conhecimento.

Orientador(a): Eliana Silva de Almeida  
Coorientador(a): Fabiane da Silva Queiroz

Maceió-AL

Abril de 2019

**Catálogo na fonte**  
**Universidade Federal de Alagoas**  
**Biblioteca Central**  
**Divisão de Tratamento Técnico**  
Bibliotecário: Marcelino de Carvalho

M538m Mendes, Yana Kellen Dioclécio.  
Medidas de centralidade para classificação automática de doenças pulmonares intersticiais em imagens de tomografia computadorizada / Yana Kellen Dioclécio Mendes. – 2019.  
47 f. : il. color.

Orientadora: Eliana Silva de Almeida.  
Co-orientadora: Fabiane da Silva Queiroz.  
Dissertação (mestrado em Modelagem Computacional de Conhecimento) – Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2019.

Bibliografia: f. 45-47.

1. Doenças pulmonares intersticiais. 2. Processamento de imagem assistida por computador. 3. Redes complexas. 4. *Closeness*. I. Título.

CDU: 004.932:616.24



UNIVERSIDADE FEDERAL DE ALAGOAS/UFAL  
INSTITUTO DE COMPUTAÇÃO  
Programa de Pós-Graduação em Modelagem Computacional de Conhecimento  
Avenida Lourival Melo Mota, Km 14, Bloco 12, Cidade Universitária  
57.072-900 Maceió AL Brasil CGC: 24.464.109/0001-48  
Telefone: (082) 3214-1364/1825



Membros da Comissão Julgadora da Dissertação de Mestrado de Yana Kellen Dioclécio Mendes, intitulada: "Medidas de Centralidade para classificação automática de Doenças Pulmonares Intersticiais em Imagens de Tomografia Computadorizada", apresentada ao Programa de Pós-Graduação em Modelagem Computacional de Conhecimento da Universidade Federal de Alagoas, em 16 de abril de 2019, às 14h00min, na sala 207 do Instituto de Computação da UFAL.

#### COMISSÃO JULGADORA

*eliana*

**Profa. Dra. Eliana Silva de Almeida**

Instituto de Computação - UFAL

Orientadora

*fabiane da silva queiroz*

**Profa. Dra. Fabiane da Silva Queiroz**

UFAL – CECA

Co-orientadora

*Tácito Trindade de Araújo Tiburtino Neves*

**Prof. Dr. Tácito Trindade de Araújo Tiburtino Neves**

UFAL – Arapiraca

*Raquel da Silva Cabral*

**Profa. Dra. Raquel da Silva Cabral**

UFAL – Arapiraca

Maceió, 16 de abril de 2019.

*Aos meus pais, Altemar e Poliana  
por sempre apoiarem as minha decisões.*

## AGRADECIMENTOS

É difícil agradecer todas as pessoas que de algum modo, nos momentos serenos e ou apreensivos, fizeram ou fazem parte da minha vida, por isso primeiramente agradeço à todos de coração.

Agradeço à Deus pelo dom da vida, presença incontestável e demonstração de amor gratuito e infinito.

Aos meus pais, Altemar e Poliana, e irmãs, Ingridy e Isadora, por compreender todos os momentos em que precisei estar ausente na constante busca da minha construção profissional. E ao meu noivo, José Soares, pela paciência e cuidado que comigo teve nesses anos de mestrado. Obrigado, sem vocês nada disso teria acontecido.

Aos meus amigos, companheiros de trabalhos e irmãos na amizade que fizeram parte da minha formação e que vão continuar presentes em minha vida.

À minha orientadora Eliana Almeida e coorientadora Fabiane Queiroz, pela paciência, dedicação e sabedoria que muito me auxiliou para conclusão desta dissertação.

À todos os professores do Programa de Pós-graduação em Modelagem Computacional do Conhecimento, que me ensinaram, incentivaram e ajudaram, direta ou indiretamente, contribuindo assim, para que eu pudesse crescer.

À Capes pelo apoio financeiro para realização deste trabalho de pesquisa.

*“Não importa o que aconteça, continue a nadar.”*  
(WALTERS, GRAHAM; *Procurando Nemo*, 2003. )

## RESUMO

As Doenças Pulmonares Intersticiais (DPIs), também denominadas *doença parenquimatosa difusa*, formam um grupo com mais de 150 patologias diferentes. Para o diagnóstico das DPIs, a tomografia computadorizada é o exame de imagem mais utilizado, pois ela é mais sensível do que a radiografia torácica, fornece imagens mais detalhadas da doença, e com isso, auxilia os médicos no seu diagnóstico. Além do exame de tomografia, tem-se utilizado a Visão Computacional para auxiliar no diagnóstico, tendo em vista que esta é uma área que tem crescido consideravelmente nos últimos anos, principalmente no que concerne a aplicações que utilizam imagens médicas. O estado da arte dessa área tem como principal característica a não existência de um algoritmo genérico que simule o processo de visão, contudo, é uma área com pesquisas bastante promissoras envolvendo diversas teorias e métodos, como as Redes Complexas. Com base nesse contexto, apresenta-se aqui um método automático para classificação de imagens de tomografia computadorizada com DPIs, onde as imagens são modeladas como Redes Complexas e a medida de centralidade *closeness* é utilizada para gerar um vetor de características junto com características extraídas pelos descritores de Haralick e LBP. Para validar o método proposto, foi treinado um classificador *K-Nearest Neighbors* (KNN) e comparado os resultados obtidos com métodos tradicionais e atuais da literatura. A partir de um conjunto de dados de 3.258 ROIs, foi possível conseguir uma taxa de classificação de 89.81%.

**Palavras-chaves:** Doenças Pulmonares Intersticiais. Textura. Redes Complexas. *Closeness*.



## ABSTRACT

Interstitial lung disease (ILD), also known as diffuse parenchymal disease, form a group with more than 150 different pathologies. For the diagnosis of ILD, the computed tomography scan is the most widely used image examination because it is more sensitive than chest thoracic radiography, provides more detailed images of the disease, and with that assists physicians in the your diagnosis. In addition to the computed tomography scan, Computational Vision has been used to aid in the diagnosis, considering that this is an area that has grown considerably in the last years, especially regarding applications that use medical images. The state of the art in this area has as main characteristic the non existence of a generic algorithm that simulates the vision process, however, it is an area with very promising research involving several theories and methods, such as Complex Networks. Based on this context, presents here an automatic method for computed tomography image classification with ILD, where the images are modeled as Complex Networks and the closeness centrality measure is used to generate a vector of characteristics along with characteristics extracted by the Haralick and LBP descriptors. To validate the proposed method, a K-Nearest Neighbors (KNN) classifier was trained and compared the results obtained with traditional and current literature methods. From a dataset of 3.258 ROIs, it was possible to achieve a rating rate of 89.81%.

**Keywords:** Interstitial Lung Disease. Texture. Complex Networks. Closeness.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplos de ROIs. (a) consolidação pulmonar, (b) área enfisematosa, (c) espessamento septal, (d) favo de mel, (e) normal, (f) opacidade em vidro fosco. <b>Fonte:</b> (PEREYRA et al., 2014) . . . . .	16
Figura 2 – Espectro Eletromagnético. <b>Fonte:</b> (FLICKR, 2011) . . . . .	20
Figura 3 – Exemplos de imagens de raios X. (a) Radiografia do tórax. (b) Angiografia da mão (c) Ressonância magnética do joelho (d) Tomografia do cérebro. <b>Fonte:</b> (GONZALEZ; WOODS, 2010) . . . . .	20
Figura 4 – Exemplos de imagens de textura. (a) Textura suave. (b) Textura rugosa. (c) Textura com regularidade. <b>Fonte:</b> Imagens retiradas da base KTH-TIPS2 (CAPUTO; HAYMAN; MALLIKARJUNA, 2005) . . . . .	21
Figura 5 – Ângulos utilizados no cálculo da matriz de co-ocorrência. <b>Fonte:</b> (HARALICK; SHANMUGAN; DINSTEIN, 1973) . . . . .	23
Figura 6 – Exemplos de grafos. <b>Fonte:</b> Autor. . . . .	24
Figura 7 – Exemplo de um grafo ponderado. <b>Fonte:</b> Autor. . . . .	25
Figura 8 – Grafo desconexo com os valores de <i>Closeness</i> . <b>Fonte:</b> Autor. . . . .	28
Figura 9 – Principais etapas do método proposto. Na etapa A uma imagem é mapeada em uma rede direcionada escalonada. Na etapa B são extraídas as informações da rede, é gerado o histograma com os valores da medida e formado o vetor de características. E na etapa C os dados do vetor são classificados. <b>Fonte:</b> Autor. . . . .	35
Figura 10 – Exemplo de uma imagem mapeada em uma rede regular. Cada vértice está conectado com outros vértices dentro de um raio $r = 2$ . <b>Fonte:</b> (GONÇALVES et al., 2016) . . . . .	36
Figura 11 – Exemplo de redes escalonadas para diferentes valores de limiar. <b>Fonte:</b> (GONÇALVES et al., 2016) . . . . .	38
Figura 12 – Exemplos da aplicação da medida de centralidade <i>closeness</i> nos seis padrões radiográficos. A rede foi escalonada com valores de $t = 30, 150, 270$ e raio fixo $r = \sqrt{5}$ . <b>Fonte:</b> Autor. . . . .	39
Figura 13 – Exemplos de imagens com DPIs que estão na base de dados . . . . .	42

## LISTA DE TABELAS

Tabela 1 – Resumo dos Trabalhos Relacionados à Dissertação . . . . .	34
Tabela 2 – Resultado dos experimentos realizados com a junção dos métodos. . . . .	43
Tabela 3 – Comparação do método proposto com outros métodos. . . . .	43
Tabela 4 – Matriz de confusão com o resultado da classificação do KNN. . . . .	44

## LISTA DE ABREVIATURAS E SIGLAS

CNN	<i>Convolutional Neural Network</i>
DCT	<i>Discrete Cosine Transform</i>
DPIs	Doenças Pulmonares Intersticiais
EM	Espectro Eletromagnético
GLCM	<i>Gray-Level Co-occurrence Matrix</i>
KNN	<i>K-Nearest Neighbor</i>
LBP	Padrão Binário Local
PI	Processamento de Imagens
TC	Tomografia Computadorizada
RC	Redes Complexas
ROIs	<i>Regions of Interest</i> (Regiões de Interesse)

## LISTA DE SÍMBOLOS

$f(x, y)$	Função de intensidade
$x$	posição espacial
$y$	posição espacial
$G$	Grafo
$V$	Conjunto de vértices
$E$	Conjuntos de arestas
$v$	Vértice
$k$	Grau do vértice
$k_i^{in}$	Grau de entrada
$k_i^{out}$	Grau de saída
$d_{i,j}$	Caminho mínimo de um vértice $i$ para um vértice $j$
$CC(i)$	Valor de <i>closeness</i>
$N$	Número de vértices
$dist(v_1, v_2)$	Distância entre vértices
$P$	Conjunto de pixels
$I$	Conjunto de intensidades
$p_i$	Pixel
$e_{v_i, v_j}$	Peso de uma arestas
$r$	Raio
$T$	Conjunto de limiar
$t$	Limiar
$D_{t_i}$	Matriz com valores de <i>closeness</i>
$D$	Matriz com a média de valores de <i>closeness</i>
$w$	Variável de intervalo

$z$	Variável de intervalo
$n$	Quantidade de imagens na base de dados
$S_{w_n, z_n}$	Vetor com a concatenação de valores de <i>closeness</i> para um intervalo de uma imagem
$\varphi^n$	Vetor com a concatenação para todos os intervalos para uma imagem
$\varphi$	Vetor com a concatenação de todas as imagens
$V$	Vetor com características extraídas com <i>closeness</i> , LBP e Haralick
$t_0$	Limiar inicial
$t_i$	Limiar de incremento
$m$	Número de vezes que o limiar é incrementado

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
<b>1.1</b>	<b>Contextualização</b>	<b>15</b>
<b>1.2</b>	<b>Definição do Problema</b>	<b>17</b>
<b>1.3</b>	<b>Objetivos</b>	<b>17</b>
<b>1.3.1</b>	<b>Objetivo Geral</b>	<b>17</b>
<b>1.3.2</b>	<b>Objetivos Específicos</b>	<b>17</b>
<b>1.4</b>	<b>Contribuições</b>	<b>18</b>
<b>1.5</b>	<b>Organização do Trabalho</b>	<b>18</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>19</b>
<b>2.1</b>	<b>Processamento de Imagens e suas Aplicações na Medicina</b>	<b>19</b>
<b>2.2</b>	<b>Textura</b>	<b>21</b>
<b>2.3</b>	<b>Teoria dos Grafos</b>	<b>23</b>
<b>2.4</b>	<b>Redes Complexas</b>	<b>25</b>
<b>2.5</b>	<b>Medidas de Centralidade</b>	<b>26</b>
<b>2.5.1</b>	<b><i>Closeness</i></b>	<b>27</b>
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>29</b>
<b>3.1</b>	<b>Extração de Características de Textura em Imagens Médicas</b>	<b>29</b>
<b>3.1.1</b>	<b>Extração de Características de Textura em Imagens com DPIs</b>	<b>31</b>
<b>3.2</b>	<b>Extração de Características de Textura baseadas no Uso de Redes Complexas</b>	<b>32</b>
<b>4</b>	<b>MÉTODO PROPOSTO</b>	<b>35</b>
<b>4.1</b>	<b>Mapeamento</b>	<b>36</b>
<b>4.2</b>	<b>Definição de um Vetor de Características</b>	<b>40</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b>	<b>41</b>
<b>5.1</b>	<b>Resultados</b>	<b>41</b>
<b>6</b>	<b>CONCLUSÃO</b>	<b>45</b>
	<b>REFERÊNCIAS</b>	<b>46</b>

# 1 INTRODUÇÃO

## 1.1 Contextualização

As Doenças Pulmonares Intersticiais (DPIs), também denominadas *doenças parenquimatosas difusas*, formam um grupo com mais de 150 patologias diferentes que afetam o espaço intersticial. O espaço intersticial inclui as paredes dos sacos de ar dos pulmões (alvéolos) e os espaços em volta dos vasos sanguíneos e vias aéreas menores (PEREYRA et al., 2014).

As DPIs resultam do acúmulo anormal de células inflamatórias no tecido pulmonar, causam falta de ar e tosse e têm aparência semelhante em exames de imagem, dificultando o diagnóstico específico para cada tipo do grupo. O diagnóstico dessas patologias é estabelecido com base no histórico completo do paciente (sintomas, histórico familiar, registro da doença, etc), no exame físico, nos exames laboratoriais e nos testes de função pulmonar, bem como nos achados visuais nas radiografias do tórax.

A Tomografia Computadorizada (TC) é um exame que utiliza radiação eletromagnética na faixa dos raios X para gerar imagens internas do corpo humano, podendo ser dos ossos, de órgãos ou tecidos. Para o diagnóstico das DPIs, a tomografia é mais sensível do que a radiografia torácica porque produz imagens que podem ser comparadas à visão que um observador atento teria, ao vasculhar, com o auxílio de uma lupa de pequeno aumento, cortes transversais obtidos em diferentes níveis pulmonares (MARTINEZ, 1998).

Na tomografia computadorizada, uma série de radiografias são analisadas por um computador, que em seguida, fornece diversos cortes (regiões de interesse) em diferentes planos. A partir dessas Regiões de Interesse (*Regios Of Interest - ROIs*), os médicos buscam por padrões radiográficos que caracterizam as DPIs. Existem seis principais padrões, são eles: Normal, Consolidação Pulmonar, Enfisematosa, Espessamento Septal, Favo de Mel e Vidro Fosco. A Figura 1 ilustra um exemplo para cada um dos seis padrões radiográficos. Mais detalhes sobre os padrões e suas causas mais importantes podem ser encontrados nas diretrizes de doenças pulmonares intersticiais da *Sociedade Brasileira de Pneumologia e Tisiologia* (BALDI et al., 2012).

Em vista de auxiliar no diagnóstico das DPIs, tem-se utilizado recursos automatizados que envolvem técnicas de Visão Computacional, sendo esta uma área que tem crescido consideravelmente nos últimos anos, principalmente no que concerne a aplicações em imagens médicas. Esse crescimento deve-se, sobretudo, a evolução da Visão Computacional e seus algoritmos. As técnicas desenvolvidas nessa área são diretamente aplicáveis em problemas reais, auxiliando na resolução de tarefas repetitivas e que envolvem um alto risco para realizá-las. Por outro lado, a resolução de tarefas utilizando Visão Computacional pode auxiliar também para registrar variáveis que uma pessoa é incapaz de estimar com exatidão, como as informações espaciais de distância percorrida, velocidade, área, volume, entre outras. A Visão Computacional tem como objetivo construir sistemas para interpretar imagens, simulando o processo de visão através da






Figura 1 – Exemplos de ROIs. (a) consolidação pulmonar, (b) área enfisematosa, (c) espessamento septal, (d) favo de mel, (e) normal, (f) opacidade em vidro fosco. **Fonte:** (PEREYRA et al., 2014)

transformação de uma imagem em uma estrutura de dados simplificada (GONÇALVES, 2010). O estado da arte dessa área tem como principal característica a não existência de um algoritmo genérico que simule o processo de visão (GONÇALVES, 2010). Sabendo disso, faz-se necessário a modelagem de algoritmos específicos para cada tipo de problema. Atualmente, tem-se inserido diversas teorias e métodos utilizando as Redes Complexas para este fim.

As Redes Complexas têm recebido um crescente interesse nas mais diversas áreas do conhecimento. Esse crescimento relaciona-se diretamente à sua flexibilidade em modelar e simular estruturas topológicas que aparecem em nosso cotidiano. As Redes Complexas recebem esse nome porque apresentam algumas propriedades topológicas não triviais, como a distribuição do grau dos vértices em leis de potência (NEWMAN, 2010).

Para a classificação das redes, medidas representativas precisam ser extraídas. Diversas medidas foram propostas na literatura, como média dos graus, coeficiente de aglomeração, medidas de centralidade, entre outras. As medidas de centralidade são uma forma de quantificar a importância de vértices ou arestas em uma rede. Essas medidas estão sendo utilizadas, por exemplo, para extrair informações da textura das imagens que foram mapeadas em grafos.

## 1.2 Definição do Problema

As DPIs possuem características clínicas e radiológicas muito semelhantes, dificultando o diagnóstico específico para cada tipo da doença no grupo. Além disso, a identificação de um padrão bem definido na imagem de tomografia não é algo recorrentemente fácil, isto pois, os padrões são semelhantes e a análise é feita em um conjunto grande de imagens, culminando em um processo lento e até impreciso. Apesar da capacidade do ser humano em resolver problemas através da visão, em alguns casos os resultados obtidos por um ser humano podem ser influenciados pela fadiga ou distração durante a realização de uma tarefa. Além disso, a análise da imagem de tomografia computadorizada, junto com todas as informações clínicas do paciente, permitem o acerto diagnóstico em aproximadamente 60% dos casos de DPIs (BALDI et al., 2012).

A partir de tais dados, é possível perceber a necessidade de melhorar a precisão do acerto diagnóstico das DPIs. Com base nessa informação surge portanto a seguinte questão geral da pesquisa:

*Como classificar automaticamente imagens de tomografia computadorizada de DPIs usando características da textura das imagens?*

Para responder tal questionamento, utilizou-se características da textura das imagens que foram extraídas por meio da medida de centralidade *closeness*, descritores de Haralick e LBP para realizar a classificação das mesmas. Escolheu-se as Redes Complexas devido à sua flexibilidade em modelar problemas, sendo aplicável em diversas áreas, como Reconhecimento de Padrões e Visão Computacional (GONÇALVES, 2010).

## 1.3 Objetivos

### 1.3.1 Objetivo Geral

Esse trabalho tem como objetivo geral classificar imagens de tomografia computadorizada de DPIs utilizando características da textura das imagens extraídas através da medida de centralidade *closeness* juntamente com os descritores de Haralick e LBP.

### 1.3.2 Objetivos Específicos

- Mapear imagens de tomografia computadorizada com DPIs em grafos;
- Aplicar métrica de centralidade *closeness* para extrair as informações dos grafos e aplicar nas imagens de tomografia o método LBP e os descritores de Haralick. E por fim, formar um vetor de características com as informações extraídas dos grafos, do método LBP e dos descritores de Haralick;

- Analisar a acurácia do método proposto e comparar o resultado com métodos clássicos da literatura com o intuito de descobrir qual técnica aplica-se melhor ao problema.

#### **1.4 Contribuições**

O presente trabalho aponta uma alternativa para classificação das DPIs com uma acurácia significativa em relação aos métodos convencionais.

Além disso, apresenta-se uma nova aplicação para as Redes Complexas, e uma nova forma de extrair informações de texturas de imagens, contribuindo para a área de Processamento de Imagem.

#### **1.5 Organização do Trabalho**

Possuindo seis capítulos, este trabalho está organizado como segue:

- Capítulo 1: No presente capítulo introdutório foram apresentados a contextualização, problemática, objetivos e contribuições;
- Capítulo 2: Apresenta-se a fundamentação teórica, abordando os principais temas e conhecimentos envolvidos no trabalho;
- Capítulo 3: Exibe-se os principais artigos relacionados a métodos de extração de características de textura em imagens médicas e em imagens de textura sintética;
- Capítulo 4: Descreve-se o método proposto deste trabalho para extração de características de textura em imagens de tomografia com DPIs;
- Capítulo 5: Mostra-se os resultados obtidos com o método proposto, bem como a comparação com os demais métodos da literatura;
- Capítulo 6: Apresenta-se as considerações finais e os trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão abordados os principais conceitos utilizados nesse trabalho. Inicia-se falando sobre o que são imagens e suas aplicações na medicina, bem como o que é textura. Serão abordados também os conceitos da Teoria dos Grafos, Redes Complexas e Medidas de Centralidade. Dentre as medidas de centralidade existentes, será tratado apenas a que utilizaremos neste trabalho que é o *closeness*.

### 2.1 Processamento de Imagens e suas Aplicações na Medicina

Uma imagem digital pode ser definida como uma função bidimensional,  $f(x, y)$ , em que  $x$  e  $y$  são coordenadas espaciais, e a amplitude de  $f$  em qualquer par de coordenadas  $(x, y)$  é chamado de nível de cinza da imagem nesse ponto. Quando  $x$ ,  $y$  e os valores de intensidade de  $f$  são quantidades finitas e discretas, tem-se uma imagem digital (GONZALEZ; WOODS, 2010).

O Processamento Digital de Imagens coloca a disposição do utilizador um conjunto de ferramentas que permitem o tratamento e manipulação das imagens de acordo com os objetivos pretendidos (GONÇALVES, 2010). A limiarização de imagens é uma ferramenta de segmentação<sup>1</sup> e consiste na identificação dos picos modais em um dado histograma de valores de intensidade. Matematicamente, o processo de limiarização resulta em uma imagem de saída  $g(x, y)$ , produto da transformação de uma imagem original em uma imagem binária (GONZALEZ; WOODS, 2010).

Essa e outras técnicas do Processamento de Imagens são usadas em várias áreas, como na medicina, na indústria, na historiografia. Para Gonzalez e Woods (2010), as áreas de aplicação do processamento de imagens são tão variadas que são categorizadas de acordo com sua fonte de energia. A principal fonte de energia para imagens utilizada atualmente é o espectro eletromagnético.

O espectro eletromagnético (EM) é o intervalo que contém todas as radiações eletromagnéticas que vão desde as ondas de rádio até os raios gama (Figura 2). Os aparelhos que fazem exames médicos por imagem trabalham com quase todo o espectro eletromagnético, diferentemente dos seres humanos, que são limitados a enxergarem o mundo apenas sob a faixa de luz visível do EM. Dentro do EM, as imagens médicas baseadas na banda do visível e de raios X são as mais utilizadas (GONZALEZ; WOODS, 2010).

Na medicina, por exemplo, as imagens geradas a partir de raios X são utilizadas para diagnóstico médico através de exames de *radiografia* (Figura 3(a)), *angiografia* (Figura 3(b)), *ressonância magnética* (Figura 3 (c)), *tomografia computadorizada* (Figura 3 (d)), dentre outros.

<sup>1</sup> A segmentação é a área do Processamento de Imagens que visa a identificação e separação de objetos em uma imagem.

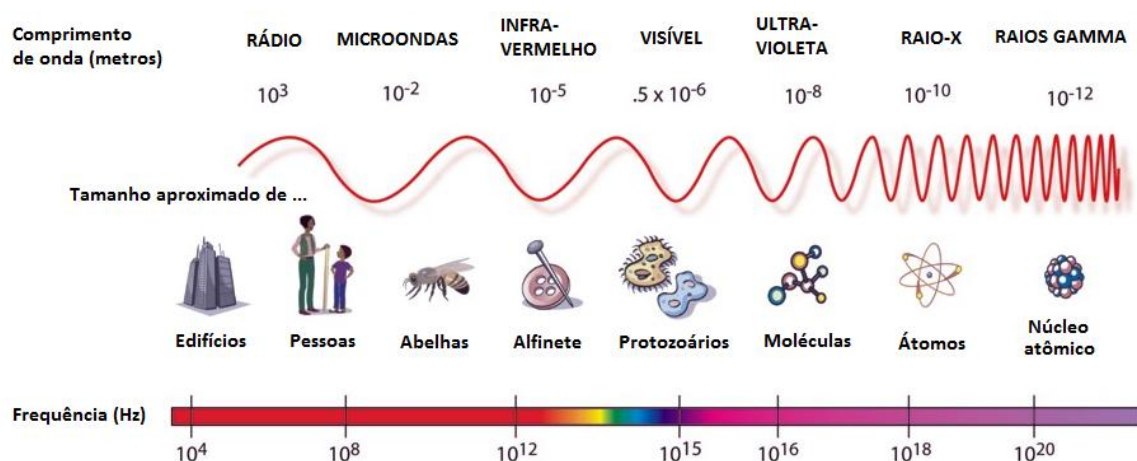


Figura 2 – Espectro Eletromagnético. **Fonte:** (FLICKR, 2011)

Uma importante utilização de raios X em imagens médicas é no exame de tomografia computadorizada, que é um exame comumente utilizado no auxílio do diagnóstico de diversas doenças, tais como doenças vasculares, lesões musculares, rastreamento de tumores. A Figura ?? exibe o esquema de como são capturados e emitidos os raios X.




Figura 3 – Exemplos de imagens de raios X. (a) Radiografia do tórax. (b) Angiografia da mão (c) Ressonância magnética do joelho (d) Tomografia do cérebro. **Fonte:** (GONZALEZ; WOODS, 2010)

De modo geral, o aparelho em que o exame é realizado, consiste em uma fonte de raios X que é acionada ao mesmo tempo em que realiza um movimento circular ao redor da região do corpo do paciente que será analisada, emitindo um feixe de raios X em forma de leque. No lado oposto a essa fonte, está localizada uma série de detectores que transformam a radiação em um sinal elétrico que é convertido em imagem digital (JÚNIOR; YAMASHITA, 2001). As imagens resultante do processo de conversão de radiação em sinal elétrico correspondem a secções (partes) da região do corpo do paciente que foi analisada (Fig. 3 (d)). Os raios X podem ser emitidos em trajetórias paralelas ou divergentes.

As imagens geradas por esses aparelhos são utilizadas no diagnóstico médico. Para auxiliar nesse diagnóstico, são extraídas as características ou atributos das imagens médicas que são selecionados geralmente através de técnicas de Processamento de Imagens. Normalmente, são extraídas características baseadas nos níveis de cinza, características de forma e textura. Neste trabalho utilizou-se a extração de característica baseada em textura.

## 2.2 Textura

A análise e interpretação de imagens são consideradas com uma das principais tarefas envolvidas na área de Visão Computacional. A análise de imagens através de texturas vem sendo utilizada para a diferenciação de diversos tipos de estruturas encontradas na imagem. Segundo Gonzalez e Woods (2010), a quantificação do conteúdo de textura é uma abordagem importante para a descrição de regiões.

Embora não exista uma única definição formal aceita pela comunidade acadêmica para definição de textura (RIBAS, 2017), algumas clássicas são as de Haralick, Shanmugan e Dinstein (1973) e Gonzalez e Woods (2010). Para Gonzalez e Woods (2010), as texturas podem ser definidas por um conjunto de padrões existentes em objetos, perceptíveis ao olho humano, e que trazem grande quantidade de informações sobre a natureza do objeto, como suavidade, rugosidade e regularidade. A Figura 4 ilustra exemplos de como são os padrões de suavidade, rugosidade e regularidade existentes nas imagens.




Figura 4 – Exemplos de imagens de textura. (a) Textura suave. (b) Textura rugosa. (c) Textura com regularidade. **Fonte:** Imagens retiradas da base KTH-TIPS2 (CAPUTO; HAYMAN; MALLIKARJUNA, 2005)

De acordo com Haralick, Shanmugan e Dinstein (1973), a textura é um conceito bidimensional, na qual uma dimensão contém as propriedades primitivas da tonalidade e a outra corresponde aos relacionamentos espaciais entre elas. No trabalho citado, as texturas definem uniformidade, densidade, aspereza, regularidade, intensidade, entre outras características em uma imagem.

Segundo Gonzalez e Woods (2010), existem três abordagens principais usadas em classificação de imagens de acordo com informação de textura. São elas: a estatística, a espectral e a estrutural.

- **Abordagem estatística:** considera a distribuição de níveis de cinza e o inter-relacionamento entre eles e são utilizadas medidas estatísticas para descrever as texturas. Medidas estatísticas comuns incluem entropia, correlação, contraste e variância, média, etc.
- **Abordagem espectral:** baseia-se em propriedades do espectro de *Fourier* e sua principal aplicação é na detecção de periodicidade global em uma imagem através da identificação de picos de alta frequência do espectro.
- **Abordagem estrutural:** representa a textura como sendo formada pela repetição de padrões que obedeçam alguma regra de posicionamento para a sua geração. Nessa abordagem, assume-se que a textura é uma composição bem definida de micro texturas que estão organizadas em uma hierarquia de arranjos espaciais que formam uma macro textura (BHARATI; LIU; MACGREGOR, 2004).

A classificação correta de qualquer textura depende muito dos descritores utilizados para caracterizá-la. Um dos descritores de textura mais amplamente utilizado foi criado por Haralick, Shanmugan e Dinstein (1973). Os descritores de Haralick, como é chamado, é um método para extração de características de textura que baseia-se em uma abordagem estatística. É um método que utiliza a relação espacial existente entre os níveis de cinza da imagem para extrair 14 parâmetros estatísticos com base na matriz de co-ocorrência.

A matriz de co-ocorrência consiste de uma contagem de quantas combinações de diferentes níveis de cinza ocorrem em uma imagem (HARALICK; SHANMUGAN; DINSTEIN, 1973). A matriz de co-ocorrência é uma matriz quadrada que tem como tamanho a quantidade de níveis de cinza da imagem a ser analisada. As combinações de ocorrência entre os níveis de cinza são calculadas nos ângulos 0, 45, 90 e 135, como mostra a Figura 5. Os demais ângulos são calculados via simetria. Após o cálculo da matriz uma outra é calculada, a nova matriz é a de probabilidade de ocorrência das combinações entre os níveis de cinza. Com essa matriz são feitos cálculos dos atributos de textura. Os mais utilizados são a energia, entropia, variância (contraste), homogeneidade, dissimilaridade e medidas de correlação.




Figura 5 – Ângulos utilizados no cálculo da matriz de co-ocorrência. **Fonte:** (HARALICK; SHANMUGAN; DINSTEIN, 1973)

Outro descritor de textura clássico, foi criado por Ojala, Pietikainen e Harwood (1996). O LBP (*Local Binary Patterns*) baseia-se na ideia de que texturas podem ser descritas por padrões espaciais locais e contraste dos níveis de cinza. Ele descreve as estruturas locais da imagem a partir de uma representação estatística dessas estruturas. O LBP combina a abordagem estatística com a abordagem estrutural. Quando aplicado a uma imagem, o LBP gera uma representação numérica das características gráficas das imagens. O LBP descreve a associação de correspondência do nível de cinza de um pixel e de seus vizinhos. O cálculo do LBP associado a um pixel é feito a partir de um conjunto de  $p$  amostras igualmente espaçadas e distribuídas sobre uma circunferência de raio  $r$  com centro sobre o pixel (OJALA; PIETIKAINEN; HARWOOD, 1996).

Apesar da intensa pesquisa nas últimas décadas e dos avanços recentes, a análise de textura ainda apresenta muitos desafios a serem abordados, principalmente no que se refere a classificação de texturas em diferentes perspectivas e em diferentes cenários de iluminação, rotação e outros (GONÇALVES et al., 2016). Atualmente, métodos de extração de textura usando Redes Complexas surgiram como um método promissor (GONÇALVES et al., 2016) e como um método que não é afetado por esses tipos de cenários. Nesse tipo de método, as imagens são mapeadas em grafos e são utilizadas medidas das Redes Complexas para extrair as informações da textura. O método proposto nesse trabalho utiliza esse novo método de extrair textura, juntamente com os métodos clássicos da literatura: LBP e descritores de Haralick. O método proposto enquadra-se em uma abordagem mista, que combina a abordagem estatística e a estrutural. O método proposto neste trabalho será detalhado no Capítulo 4.

### 2.3 Teoria dos Grafos

Para entender as Redes Complexas, faz-se necessário primeiro compreender os conceitos da Teoria dos Grafos, pois as Redes Complexas são uma área de pesquisa que faz uso da mesma.



A Teoria dos Grafos é um ramo da matemática que estuda as relações entre os objetos de um determinado conjunto (SCHEINERMAN, 2006). A estrutura usada para estudar essas relações entre objetos são os grafos, que são formados por um conjunto de vértices unidos por arestas. Matematicamente, um grafo é um par  $G = (V, E)$ , onde  $V$  é o conjunto de vértices e  $E$  são as arestas do grafo (SCHEINERMAN, 2006).

Os grafos podem ser direcionados e não-direcionados. Em um grafo direcionado, cada aresta tem uma direção que conecta um nó origem a um nó destino, como ilustra a Figura 6 (a). Exemplos de grafos direcionados são as redes de telefonia e mensagens de *emails*, nos quais as ligações e mensagens são direcionadas de uma pessoa para outra.

Os grafos não-direcionados são grafos que não há direção especificada nas ligações, ou seja, se um vértice  $v_1$  está ligado ao vértice  $v_2$ , simultaneamente o vértice  $v_2$  estará ligado ao vértice  $v_1$  (Figura 6 (b)).

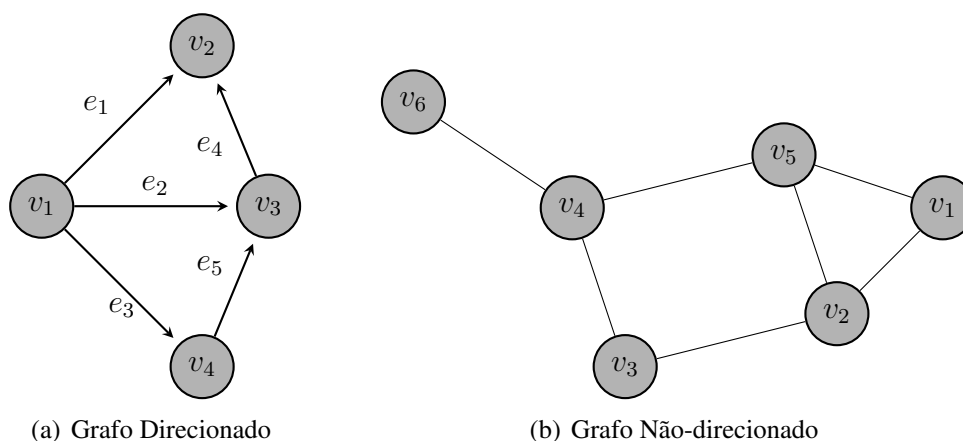


Figura 6 – Exemplos de grafos. **Fonte:** Autor.

Dependendo do tipo do grafo as arestas podem ter valores de pesos. Os grafos com peso nas arestas são chamados de grafos ponderados. Um grafo é dito ser ponderado quando existe uma ou mais funções relacionando os vértices e/ou arestas com um conjunto de números. Na Figura 7 tem-se um grafo direcionado ponderado onde as relações entre os vértices e os pesos existentes para cada aresta são exibidos. As arestas estão com espessuras diferentes conforme o seu peso. Como exemplos de grafos ponderados, tem-se as redes de chamadas móveis, onde o peso pode representar o número total de minutos que dois indivíduos conversam no telefone, e na rede elétrica, o peso é a quantidade de corrente que flui através de uma linha de transmissão. Além desses grafos, tem-se o grafo regular que é um grafo onde cada vértice tem o mesmo número de adjacências, ou seja, quando todos os seus vértices tem o mesmo grau.

Uma propriedade importante do vértice é o seu grau. Ele representa o número de arestas que estão conectados a um vértice qualquer em um grafo. Matematicamente, dado um grafo não-direcionado e não-ponderado, o grau  $k_i$  de um vértice  $v_i$  representa a somatória das arestas que incidem no vértice  $v_i$ . Para um grafo direcionado, cada vértice  $v_i$  tem um grau de entrada  $k_i^{in}$ ,




Figura 7 – Exemplo de um grafo ponderado. **Fonte:** Autor.

representando o número de arestas que apontam para o vértice  $v_i$ , e de saída  $k_i^{out}$ , representando o número de arestas que apontam do vértice  $v_i$  para outros vértices. O grau  $k_i$  do vértice  $v_i$  em um grafo direcionado é dado por:

$$k_i = k_i^{in} + k_i^{out}$$

Um outro aspecto importante a ser considerado em um grafo são seus caminhos. Este pode ser definido por uma sequência de vértices, sem repetição, onde existe uma aresta entre cada par de vértice na sequência. A partir do caminho pode-se calcular o caminho mínimo. O caminho mínimo é um aspecto relacionado a estrutura global de um grafo. O caminho mínimo  $d_{ij}$  é o número mínimo de arestas que interligam dois vértices  $v_i$  e  $v_j$  (BARABASI, 2003). Por exemplo, no grafo da Figura 6 (b), o caminho mínimo entre o vértices  $v_2$  e  $v_4$  é igual a 2.

Além dos grafos direcionados e não-direcionados, existem os grafos conexos e os grafos desconexos. Segundo Scheinerman (2006), um grafo  $G = (V, E)$  é conexo se existir um caminho entre qualquer par de vértices. Caso contrário, esse grafo é dito desconexo, ou seja, se existir pelo menos um par de vértices que não está ligado a nenhum caminho.

## 2.4 Redes Complexas

Redes Complexas é uma teoria que engloba o formalismo dos grafos e a análise de mecânica estatística<sup>2</sup>. As Redes Complexas são representadas através de grafos. Geralmente, as Redes Complexas possuem um conjunto de vértices e arestas compostos por um grande número de componentes e propriedades topológicas particulares (BARABASI, 2003).

Os primeiros trabalhos, utilizando redes complexas, buscaram definir os conceitos para caracterizar a topologia de redes do mundo real (NEWMAN, 2010). Com isso, foi possível identificar princípios e propriedades estatísticas em comum na maioria das redes reais avaliadas.

Devido a sua grande capacidade de generalização e caráter multidisciplinar, as redes têm sido aplicadas nos mais variados problemas. É possível, por exemplo, modelar toda a estrutura física de uma grande rede de computadores tal como a Internet. Nesse caso, os computadores

<sup>2</sup> A mecânica estatística é o ramo da física que estuda o comportamento de sistemas mecânicos macroscópicos (HUANG, 1990).

conectados à Internet referem-se aos vértices da rede enquanto que os cabos e meios de transmissão representam as arestas do grafo. Outras analogias podem ser também utilizadas, tais como o conteúdo de páginas WEB, relações sociais entre grupos de pessoas, redes organizacionais ou de negócios entre companhias, redes neurais, redes metabólicas, cadeia alimentar, entre outras.

Além desses exemplos, Antiqueira et al. (2005) propõe a modelagem de textos através de Redes Complexas e usa essa modelagem para avaliar a qualidade do texto. Em seu modelo, um texto é representado por uma rede complexa, na qual cada palavra é um vértice e cada aresta representa uma relação de adjacência entre dois vértices, ou seja, para cada par de palavras consecutivas, existe uma aresta direcionada correspondente na rede. Cada aresta contém um peso que indica o número de vezes que as respectivas associações de palavras ocorrem no texto. O objetivo dessa representação é codificar as relações entre os conceitos de um texto.

O trabalho de Alexandre et al. (2003) por sua vez, propõe um modelo para a avaliação de sumários produzidos automaticamente baseado em cinco diferentes representações de redes complexas. Neste trabalho, é apresentado um sumário extrativo que usa técnicas estatísticas para determinar a ideia central dos textos por ele sumarizados. Baseia-se na simulação da sumarização humana, primeiro identificando a ideia principal do texto e, então, acrescenta informações adicionais ou complementares. Dessa forma, o sumário primeiro procura a sentença que melhor expressa a ideia principal do texto e baseado nela são escolhidas as demais sentenças, que vão compor o extrato textual.

Embora as Redes Complexas tenham sido aplicadas com sucesso nestes exemplos, ainda existe um amplo campo de pesquisa a ser desenvolvido em diversas áreas, como na Visão Computacional e no Reconhecimento de Padrões. Nestas áreas, as Redes Complexas ainda estão inexploradas e poucas pesquisas são encontradas na literatura (GONÇALVES, 2010). Os trabalhos que foram encontrados na literatura que utilizaram as redes juntamente com a Visão Computacional são relatados no Capítulo 3.

Em geral, quando utiliza-se as Redes Complexas com a Visão Computacional para extrair características das imagens, a seguinte metodologia é aplicada: modela-se a imagem em uma rede para, posteriormente, utilizar aspectos topológicos da rede na caracterização e classificação da textura. Esses aspectos topológicos são extraídos utilizando medidas existentes nas Redes Complexas, como por exemplo as medidas de centralidade.

## **2.5 Medidas de Centralidade**

Ao analisar uma rede, um aspecto importante a ser considerado consiste em descobrir quais são os seus vértices ou arestas que são mais importantes (ou centrais). As medidas de centralidade são uma forma de quantificar essa importância. De um modo geral, uma medida de centralidade atribui um valor real a cada vértice da rede, onde se espera que os valores produzidos forneçam uma classificação dos vértices com base na sua relevância (LU et al., 2016).

Existem vários tipos de medida de centralidade, e dentre elas estão: a centralidade de grau baseada nos vizinhos imediatos dos vértices, a centralidade baseada em distâncias.

A centralidade de grau, assim chamada por ser uma função do grau de um vértice, conta o número de arestas incidentes a um vértice do grafo. Já a medida de centralidade baseada em distância, tem-se a *closeness*, que está relacionada com a distância total de um vértice a todos os demais vértices do grafo, e a *betweenness* que mede quantos caminhos mínimos existem entre todos os pares de vértices do grafo que passam através de um determinado vértice.

Diante de tais medidas, a abordagem proposta neste trabalho utilizará a medida de centralidade *closeness*, para extrair as características de textura das imagens juntamente com LBP e os descritores de Haralick. Escolheu-se a *Closeness* por conta do seu alto desempenho e aplicabilidade na resolução do problema proposto dentre as outras medidas existentes (GONÇALVES, 2010).

### 2.5.1 Closeness

A medida de centralidade *Closeness* é calculada com base no número de caminhos mínimos de um vértice em relação aos outros vértices do grafo (LU et al., 2016). Para essa medida de centralidade é mais importante o vértice não estar longe demais dos restantes dos vértices da rede do que ter muitas conexões.

Para um grafo conexo  $G$ , a medida *Closeness* de um vértice  $v_i$  é dada pelo inverso das somas das distâncias dos caminhos mínimos de  $v_i$  para todos os outros vértices da rede:

$$CC(i) = \frac{N - 1}{\sum_{j \neq i} d_{ij}}, \quad (2.1)$$

onde  $N$  é o número de vértices do grafo.

Porém, a definição original tem uma grande lacuna: quando a rede não está conectada (grafo desconexo) existem alguns pares de nós com  $d_{ij} = \infty$ . Assim, uma forma mais comum de calcular essa medida de centralidade é usar a versão harmônica, ou seja, a soma dos inversos das distâncias dos caminhos mínimos, atribuindo o valor zero no resultado do quociente de  $\frac{1}{\infty}$ . Sabendo disso, a Equação 2.1 é reformulada e é apresentada da seguinte forma:

$$CC(i) = \frac{1}{N - 1} \sum_{j \neq i} \frac{1}{d_{ij}}. \quad (2.2)$$

Deste modo, quanto maior o valor de *Closeness*, mais central é o vértice. Em geral, o vértice com o maior valor de *Closeness* tem a melhor visão do fluxo de informações (LU et al., 2016).

Para ilustrar a medida de centralidade *Closeness*, consideremos o grafo dado na Figura 8. As distâncias entre o vértice  $v_1$  e todos os demais vértices podem ser vistas no grafo a seguir e

são dadas por:

$$\text{dist}(v_1, v_2) = 1; \quad \text{dist}(v_1, v_3) = 2;$$

$$\text{dist}(v_1, v_4) = 2; \quad \text{dist}(v_1, v_5) = 3;$$

Pela Equação 2.2, a *Closeness* do vértice  $v_1$  é dada por:

$$CC(i) = \frac{1}{n-1} \sum_{j \neq i} \frac{1}{d_{ij}}$$

$$CC(i) = \frac{1}{4} \cdot \left( 1 + \frac{1}{2} + \frac{1}{2} + \frac{1}{3} \right)$$

$$CC(i) = 0.58.$$

A Figura 8 mostra o grafo com os valores da métrica de centralidade para todos os vértices que foram calculadas com base na Equação 2.2. Nesse grafo, observa-se que o vértice  $v_2$  possui o maior valor de *Closeness*, indicando que ele é o mais central do grafo.




Figura 8 – Grafo desconexo com os valores de *Closeness*. **Fonte:** Autor.

### 3 TRABALHOS RELACIONADOS

A textura tornou-se fundamental para reconhecer objetos e cenas em diferentes aplicações da Visão Computacional e com isso diversas áreas de conhecimento foram beneficiadas, incluindo inspeção industrial, sensoriamento remoto de recursos terrestres, imagens médicas, reconhecimento de objetos, recuperação de imagens baseada em conteúdo, dentre outras áreas (GONÇALVES et al., 2016).

Neste capítulo, serão apresentados alguns métodos convencionais (SEGUÍ et al., 2012; HU et al., 2016; PEREYRA et al., 2014; FERREIRA; OLIVEIRA; AZEVEDO-MARQUES, 2017) e métodos que utilizaram as Redes Complexas (COUTO; BACKES; BARCELOS, 2017; GONÇALVES et al., 2016) para extrair informações de textura de imagens. A Tabela 1 exhibe todos os trabalhos que estão relacionados com esta dissertação e que estão descritos neste capítulo.

A maioria das pesquisas sobre classificação de textura visa encontrar um descritor de textura eficiente, poderoso e discriminativo. Os descritores de textura extraem as características e os representam eficientemente, proporcionando maior precisão de classificação, independentemente do classificador utilizado (SIMON; UMA, 2018). Na literatura, descritores de texturas convencionais como Padrão Binário Local (LBP - *Local Binary Patterns*) (WANG; HE, 1990), Matriz de Co-Ocorrência dos Nível de Cinza (GLCM - *Gray-Level Co-Occurrence Matrix*) (HARALICK; SHANMUGAN; DINSTEN, 1973), Filtros de Gabor (FOGEL; SAGI, 1989), *Wavelet* (BENTLEY; MCDONNELL, 1994), descritores de *Fourier* (CRIMMINS, 1982), são discutidos e utilizados por diversos trabalhos.

#### 3.1 Extração de Características de Textura em Imagens Médicas

A partir do levantamento bibliográfico, foram encontrados os trabalhos de Seguí et al. (2012), Ferreira, Oliveira e Azevedo-Marques (2017), Neto et al. (2014) que utilizaram métodos de extração de características de textura em imagens médicas.

O trabalho de Seguí et al. (2012) apresentou um método de detecção e segmentação do conteúdo intestinal em imagens de cápsula endoscópica. O método proposto pelos autores é dividido em duas partes: a parte de detecção, que utiliza histogramas de cores e descritor de textura para extrair informações das imagens e realiza a classificação utilizando SVM (*Support Vector Machine*), e a segunda parte faz a segmentação com base no conteúdo da imagem e pode ser rotulado em claro, turvo e bolhas. Para extrair características de textura é utilizado um detector de recurso robusto acelerado (*Speeded-Up Robust Feature* - SURF). O método SURF é um detector e descritor de ponto de interesse invariante de escala e rotação. Segundo os autores, a escolha desse método em relação aos outros métodos da literatura, como por exemplo filtro de *Gabor*, é o custo computacional, sendo este 50 vezes mais rápido. Este trabalho está relacionado

com a dissertação por utilizar descritores de textura em imagens médicas.

Os trabalhos de Ferreira, Oliveira e Azevedo-Marques (2017), Neto et al. (2014) utilizaram a extração de características de textura em imagens de tomografia computadorizada. Em seu trabalho, Ferreira, Oliveira e Azevedo-Marques (2017) relataram sobre um método que realiza a classificação de nódulos pulmonares com base nas características de textura e nitidez de margem em imagens de tomografia. Neste trabalho, as características de textura foram extraídas de uma versão estendida da matriz de co-ocorrência formada em 3 dimensões obtida a partir do volume do nódulo. O método 3D GLCM obtém a partir de um único volume de imagem: a probabilidade de ocorrência de pares de pixels com espaçamento entre eles de  $\delta x$ ,  $\delta y$  e  $\delta z$  nas dimensões  $x$ ,  $y$  e  $z$ , respectivamente, dada a distância  $d$  e orientação  $\theta$ . As estatísticas do histograma de segunda ordem são calculadas a partir do GLCM, produzindo os atributos de textura. Os atributos de textura utilizados neste trabalho foram energia, entropia, momento de diferença inversa, inércia, variância, sombra, rendimento, correlação e homogeneidade, sugeridos por Haralick, Shanmugan e Dinstein (1973). O vetor de características de textura foi obtido por meio do cálculo dos nove atributos computados das matrizes de co-ocorrência nas orientações  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$  e distância 1. Também foi implementada uma análise de nitidez de margem 3D para caracterizar nódulos pulmonares, em que uma análise estatística de dados foi realizada extraíndo atributos de uma matriz ordenada composta pelas intensidades do nível de cinza dos pixels das linhas perpendiculares que traçavam as bordas de todos os nódulos. O vetor formado por ambos os métodos foram classificados por vários classificadores, como o KNN, SVM, *Naive Bayes*. Este trabalho está relacionado com a dissertação por utilizar descritores de textura em imagens de tomografia.

No trabalho de Neto et al. (2014) é abordado um método para a detecção automática de fissuras pulmonares em imagens de TC do tórax. O método proposto consiste na análise de padrões de textura, classificadas por uma rede neural MLP e posteriormente pós-processada utilizando análise de componentes conectados e morfologia matemática. A extração das características de texturas é realizada por meio de estatísticas de segunda ordem, baseado na repetição de pares de pixels proposto por Haralick, Shanmugan e Dinstein (1973). As estatísticas de segunda ordem são calculadas com base na função de probabilidade da co-ocorrência de dois pares de pixels na imagem. A dissertação desenvolvida está relacionada com o trabalho de Neto et al. (2014) por utilizar imagens de tomografia e os descritores de Haralick.

Em todos os trabalhos citados até o momento, existe um fator limitante em seus métodos. Eles utilizaram apenas uma abordagem estatística para classificar as texturas das imagens. Esse tipo de abordagem, dependendo das imagens utilizadas, não conseguem descrever bem as texturas, uma vez que é considerado apenas aspectos locais nas imagens. Uma forma de melhorar esses métodos seria o uso de uma abordagem mista, que extrairia mais informações das texturas, e conseqüentemente, aumentaria a taxa de acerto do classificador. Ou, utilizar uma outra metodologia para extração de características de textura que é com uso de Redes Complexas.

Sabendo disso, no método proposto neste trabalho, utiliza-se uma abordagem mista na qual é empregado o método com Redes Complexas junto com os métodos clássicos, LBP e descritores de Haralick.

### 3.1.1 Extração de Características de Textura em Imagens com DPIs

Vários métodos têm sido desenvolvidos com a finalidade de detectar e caracterizar as DPIs, sendo a análise de textura a sua principal ferramenta. Dentre esses métodos temos os trabalhos de Martins et al. (2005), Pereyra et al. (2014), Almeida, Rangayyan e Azevedo-marques (2015b), Almeida, Rangayyan e Azevedo-marques (2015a), Anthimopoulos et al. (2014), Joyseeree, Muller e Depeursing (2018).

Martins et al. (2005) em seu trabalho relatam sobre um método para caracterizar DPIs em radiografias frontais de tórax, com base na análise de atributos estatísticos de textura. Eles utilizaram dentre os atributos estatísticos energia, contraste, correlação, momento da diferença inversa, média da soma, média da diferença, entropia. Os valores obtidos para cada atributo formaram os vetores de atributos para cada uma das regiões dos pulmões previamente subdivididas. As imagens foram, então, classificadas através desses vetores utilizando o classificador KNN. O relacionamento do trabalho desenvolvido pelo autor com a desta dissertação está na utilização de extração de textura utilizando abordagem estatística em imagens de tomografia com DPIs.

Outro trabalho que também faz uso da abordagem estatística é o de Pereyra et al. (2014). Em seu trabalho é descrito um método para extração de características de textura em imagem de tomografia computadorizada com DPIs. Eles utilizaram estatística de primeira ordem, os descritores de textura de Haralick, as informações estatísticas extraídas das transformadas de *Fourier* e os valores de dimensão fractal como atributos para a classificação. O método deste trabalho utilizou a mesma base de dados usada no trabalho de Pereyra et al. (2014). O resultado da comparação do método proposto neste trabalho com o de Pereyra et al. (2014) pode ser encontrado no Capítulo 5. A dissertação desenvolvida está relacionada com o trabalho de Pereyra et al. (2014) por utilizar a mesma base de dados e por utilizar abordagem estatística.

O trabalho de Almeida, Rangayyan e Azevedo-marques (2015a) trata de uma análise estatística das características quantitativas extraídas pelo trabalho de Pereyra et al. (2014). Neste trabalho, um modelo de mistura gaussiana é usado como um modelo estatístico para cada atributo que foi extraído por Pereyra et al. (2014). Eles estimam seis funções de densidade de probabilidade gaussianas que foram relacionados aos seis padrões radiográficos existentes. Outro trabalho de Almeida, Rangayyan e Azevedo-marques (2015b) relata sobre uma extensão do primeiro trabalho. Neste, a partir dos modelos de mistura gaussiana, as funções de participação *fuzzy*<sup>1</sup> foram obtidas por meio de uma transformação de probabilidade-possibilidade e por uma análise estatística. Em ambos os trabalhos de Almeida, Rangayyan e Azevedo-marques (2015a)

<sup>1</sup> Os conjuntos *fuzzy* foram propostos pela primeira vez por Zadeh (1965). Para mais detalhes ver o trabalho de Zadeh (1965) (ZADEH, 1965)



não utilizou-se as imagens de TC com DPIs, e sim as características extraídas pelo trabalho de Pereyra et al. (2014). Com isso, percebe-se como os métodos de Almeida, Rangayyan e Azevedo-marques (2015a) podem ser dependentes das características extraídas por Pereyra et al. (2014). Se o método de extração de características proposto por Pereyra et al. (2014) não conseguir extrair bem as características das imagens de TC com DPIs, os métodos de Almeida, Rangayyan e Azevedo-marques (2015a) serão afetados. Dessa forma, não realizou-se comparação do método proposto neste trabalho com os métodos de Almeida, Rangayyan e Azevedo-marques (2015a), visto que o método proposto superou o método de Pereyra et al. (2014) (ver Cap. 5).

No trabalho de Anthimopoulos et al. (2014) a extração de características de textura nas imagens de tomografia com DPIs foi realizada com uso da transformada discreta de cosseno (*Discrete Cosine Transform - DCT*)<sup>2</sup>. Para isso, eles formaram um banco de filtros constituído pelas funções DCT, que cobre todo o espectro de frequência de uma área local da imagem. Depois, quantis são calculados para descrever a distribuição das frequências locais que caracterizam a textura da imagem. Com os dados dos quantis, eles formaram um vetor de características que foi utilizado no processo de classificação. O relacionamento do trabalho desenvolvido pelo autor com a desta dissertação está apenas na utilização de extração de textura em imagens de tomografia com DPIs.

Assim como os métodos da seção anterior (3.1), um fator limitante desses métodos é que eles utilizaram apenas um tipo de abordagem, estatística ou espectral, e com isso não descrevem bem a textura das imagens, pois são abordagens locais. Além disso, esses métodos foram criados para tipos específicos de base de dados, mesmo sendo a mesma doença, as imagens podem vir com características diferentes em cada base.

Vários outros trabalhos que usam imagens com DPIs podem ser encontrados na literatura, porém a maioria desses trabalhos utilizam rede neural convolucional (*Convolutional Neural Network - CNN*) para extrair características de textura e classificar as imagens, como é o caso de Anthimopoulos et al. (2016), Hattikatti (2017), Cardoso et al. (2018), contudo, esse tipo de metodologia não é o foco deste trabalho.

### **3.2 Extração de Características de Textura baseadas no Uso de Redes Complexas**

Na literatura, o uso de Redes Complexas é empregado em diferentes problemas de Visão Computacional e Processamento de Imagens, tais como: segmentação (MORRIS; LEE, 1986; XU; UBERBACHER, 1997), análise de texturas (BACKES; CASANOVA; BRUNO, 2009), reconhecimento de objetos em cenas (MATAS; MARIK; KITTLER, 1995), entre outros. No entanto, devido ao objetivo deste trabalho, o foco nesta seção serão os métodos de extração de características de texturas. Em geral, os métodos de extração de características baseado em Redes Complexas utilizam a seguinte metodologia: modelagem da imagem em uma rede para,

---

<sup>2</sup> O DCT descreve um sinal discreto como uma combinação linear de funções cosseno oscilando em frequências diferentes.

posteriormente, utilizar aspectos topológicos da rede na caracterização e classificação da textura. Trabalhos recentes que utilizaram essa metodologia são os de Gonçalves et al. (2016) e Couto, Backes e Barcelos (2017).

No método proposto por Gonçalves et al. (2016), uma imagem é mapeada para uma rede direcionada regular, em que cada pixel se torna um vértice da rede. Dois vértices são conectados se estão dentro de uma vizinhança determinada por um valor de raio. Em seguida, com base na análise da diferença nos níveis de cinza dos pixels relativos aos vértices da rede, uma função de limiar é aplicada para transformar a rede direcionada regular em uma rede direcionada escalonada. A rede escalonada é a rede resultante da transformação da rede direcionada regular em uma rede com menos arestas. Vários valores de limiar são utilizados para se obter múltiplas redes escalonadas. Caminhadas aleatórias são por fim realizadas, afim de estimar a atividade em um dado grafo, que é representado por um histograma gerado pela associação dos valores de centralidade do grau (*in-degree*) dos vértices com o número de passadas do caminhante nestes mesmos vértices. Por fim, partindo do número de passadas do caminhante, é gerado um vetor de características com os histogramas das atividades para diferentes grafos obtidos pela variação de diversos valores de limiares e de raio. A dissertação desenvolvida está relacionada com o trabalho de Gonçalves et al. (2016) por utilizar do método de mapeamento proposto no trabalho do autor.

Outro trabalho que aborda a caracterização de texturas com grafos foi proposto por Couto, Backes e Barcelos (2017), nesse artigo é apresentado o descritor de textura que utiliza caminhadas determinísticas e valores *in-degree* dos vértices para assim gerar um vetor de características. As caminhas determinísticas são iniciadas por caminhantes que partem de um dos vértices da rede e em seguida, informações são extraídas sobre essas caminhadas. As caminhadas são chamadas de determinísticas, por que cada caminhante vai para o vértice mais próximo que não tenha sido visitado nos últimos passos. A regra da caminhada pode ser modificada para ir em direção ao vértice mais próximo ou mais distante do vértice atual. O relacionamento do trabalho desenvolvido pelo autor com a desta dissertação está apenas na utilização de extração de textura com base no uso de Redes Complexas.

Os trabalhos de Gonçalves et al. (2016) e Couto, Backes e Barcelos (2017), mostram-se promissores e eficientes, contudo eles apresentam o problema da extração de características texturas em imagens através de aspectos locais da rede uma vez que análise é feita considerando-se apenas valores de grau de entrada da rede. Contudo, descritores globais costumam ser mais comumente usados em problemas de descrição e classificação de objetos em imagens (BHARATI; LIU; MACGREGOR, 2004). Métodos de abordagem global descrevem a imagem como um todo para generalizar um dado objeto. A exemplo de métodos globais empregados na descrição automática de texturas em imagens, tem-se o tradicional LBP (*Local Binary Patterns*). Para mais informações sobre o LBP tem-se o trabalho de Liu et al. (2017) que fornece uma revisão sistemática dos trabalhos que utilizaram LBP ou que fizeram variantes do método.

Trabalho	Autor	Especificação
Categorization and Segmentation of Intestinal Content Frames for Wireless Capsule Endoscopy	Seguí et al. (2012)	O trabalho visa a detecção e segmentação do conteúdo intestinal em imagens de cápsula endoscópica utilizando histograma de cor e descritor de textura.
Characterization of Pulmonary Nodules Based on Features of Margin Sharpness and Texture	Ferreira, Oliveira e Azevedo-Marques (2017)	O trabalho realiza classificação de nódulos pulmonares com base nas características de textura e nitidez de margem em imagens de tomografia computadorizada.
Segmentação 3D de Fissuras Pulmonares em Imagens de TC utilizando Texturas	Neto et al. (2014)	O trabalho mostra um método para detecção automática de fissuras pulmonares em imagens de TC do tórax utilizando análise de padrões de textura e classificando com uma rede neural MLP.
Caracterização de Lesões Intersticiais de Pulmão em Radiograma de Tórax utilizando Análise Local de Textura	Martins et al. (2005)	O trabalho relata sobre um método para caracterizar DPIs em radiografias frontais de tórax com base na análise de atributos estatísticos de textura.
Fractal Analysis for Computer-aided Diagnosis of Diffuse Pulmonary Diseases in HRCT Images	Pereyra et al. (2014)	O trabalho relata sobre um método para extração de características de textura em imagem de tomografia computadorizada com DPIs utilizando estatística de primeira ordem, os descritores de textura de Haralick, as informações estatísticas extraídas das transformadas de <i>Fourier</i> e os valores de dimensão fractal como atributos para a classificação.
Gaussian Mixture Modeling for Statistical Analysis of Features of High-Resolution CT Images of Diffuse Pulmonary Diseases	Almeida, Rangayyan e Azevedo-marques (2015a)	O trabalho trata sobre uma análise estatística das características quantitativas extraídas pelo trabalho de Pereyra et al. (2014), no qual um modelo de mistura gaussiana é usado como um modelo estatístico para cada atributo que foi extraído.
Fuzzy Membership Functions for Analysis of High-Resolution CT Images of Diffuse Pulmonary Diseases	Almeida, Rangayyan e Azevedo-marques (2015b)	O trabalho relata sobre uma extensão do primeiro trabalho. Neste, a partir dos modelos de mistura gaussiana, as funções de participação <i>fuzzy</i> foram obtidas por meio de uma transformação de probabilidade-possibilidade e por uma análise estatística.
Classification of Interstitial Lung Disease Patterns Using Local DCT Features and Random Forest	Anthimopoulos et al. (2014)	O trabalho aborda sobre a extração de características de textura nas imagens de tomografia com DPIs utilizando a transformada discreta de cosseno.
Texture Recognition based on Diffusion in Networks	Gonçalves et al. (2016)	O trabalho aborda sobre um método de extração de textura utilizando o mapeamento das imagens em grafos e aplicando caminhas aleatórias para extrair informações.
Texture Characterization via Deterministic Walks' Direction Histogram Applied to a Complex Network based Image Transformation	Couto, Backes e Barcelos (2017)	O trabalho apresenta um descritor de textura que utiliza caminhas determinísticas e valores <i>in-degree</i> dos vértices para assim gerar um vetor de características.

Tabela 1 – Resumo dos Trabalhos Relacionados à Dissertação

## 4 MÉTODO PROPOSTO

Neste capítulo, discute-se o método proposto no qual, de modo geral, cada imagem de tomografia computadorizada é mapeada em um conjunto de redes escalonadas, nas quais valores da medida de centralidade *closeness* são computados afim de extrair as características de textura das imagens juntamente com os descritores de Haralick e LBP.

As principais etapas do método proposto são apresentadas na Figura 9. Na etapa de mapeamento (Seção 4.1), uma imagem é mapeada como uma rede direcionada regular e transformações de eliminação de arestas são aplicadas sobre a rede, transformando-a em uma rede escalonada. As redes escalonadas são redes resultantes do processo de limiarização. Na etapa de extração de características (Seção 4.2), as características da textura são extraídas da rede com o uso da medida de centralidade *closeness*. Os valores da medida são agrupados e é formado um vetor com esse valores. Por fim, é construído o vetor de características final composto pelo vetor com os valores da medida de centralidade e de características extraídas das imagens através dos descritores de Haralick e LBP. O vetor de características final é utilizado no processo de classificação.




Figura 9 – Principais etapas do método proposto. Na etapa A uma imagem é mapeada em uma rede direcionada escalonada. Na etapa B são extraídas as informações da rede, é gerado o histograma com os valores da medida e formado o vetor de características. E na etapa C os dados do vetor são classificados. **Fonte:** Autor.

## 4.1 Mapeamento

O processo de mapeamento da imagem para uma rede foi realizado com base no método proposto por Gonçalves et al. (2016). Considerou-se que uma imagem consiste em um par  $(P, I)$ , onde  $P$  é um conjunto finito de pixels  $p_i$  e  $I$  é o conjunto das intensidades dos pixels e está no intervalo de 0 à 255.

As arestas da rede são definidas pela distância Euclidiana. A distância Euclidiana é a distância entre dois pontos, que pode ser provada pela aplicação repetida do teorema de Pitágoras. A distância euclidiana entre os pontos  $A = (a_1, a_2)$  e  $B = (b_1, b_2)$  é definida como:  $\sqrt{(a_1 - a_2)^2 + (b_1 - b_2)^2}$ . Utiliza-se a distância Euclidiana porque é a mesma distância utilizada no método de mapeamento proposto por Gonçalves et al. (2016). Não realizou-se experimentos com outras distâncias.

Inicialmente a rede direcionada é obtida conectando dois vértices  $v_i$  e  $v_j$  se a distância euclidiana entre os pixels  $p_i$  e  $p_j$  for igual ou menor que um determinado raio  $r$ . O raio  $r$  limita as conexões espacialmente distantes na imagem. A Figura 10 ilustra o resultado do mapeamento da imagem em rede direcionada regular. Neste trabalho, utiliza-se o raio fixo, e não a combinação de diferentes raios como faz Gonçalves et al. (2016) porque considera-se que o raio fixo igual a 4, diante dos demais raios testados, melhor se enquadra no problema proposto, uma vez que as bordas dos objetos na imagem conseguiram ser bem descritas com esse raio. Além disso, esta escolha, reduz o custo computacional associado ao método.

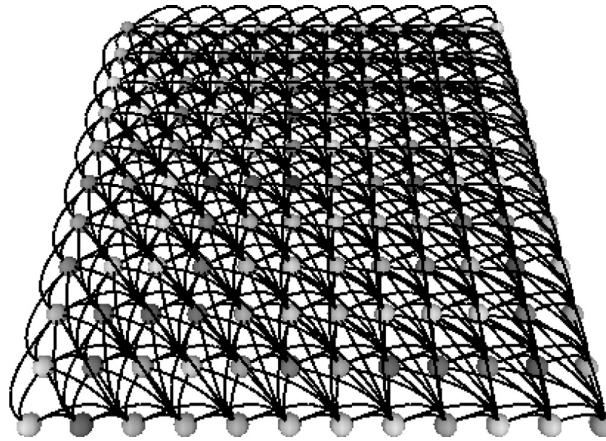


Figura 10 – Exemplo de uma imagem mapeada em uma rede regular. Cada vértice está conectado com outros vértices dentro de um raio  $r = 2$ . **Fonte:** (GONÇALVES et al., 2016)

Para cada ligação, um peso é definido pela diferença de intensidade dos pixels e este é atribuído a aresta de acordo com a Equação 4.1:

$$e_{v_i, v_j} = \begin{cases} I(p_i) - I(p_j), & \text{se } dist(p_i, p_j) \leq r \\ NaN, & \text{caso contrário} \end{cases} \quad (4.1)$$

em que  $dist(p_i, p_j)$  é a distância euclidiana entre os pixels  $p_i$  e  $p_j$ . A direção da rede é obtida levando em consideração apenas as bordas dos objetos, que se estendem dos pixels com valores de níveis de cinza maiores para os pixels com valores de níveis de cinza menores.

A seguir tem-se o Algoritmo 1 que demonstra como a imagem foi mapeada para a rede direcionada regular. Recebe-se como entrada a imagem, em forma de matriz, e o valor do raio que será utilizado, e tem-se como saída a rede direcionada regular. Para criar uma aresta na rede, verificou-se se a distância euclidiana entre dois pixels é menor que a raiz quadrada do raio. Se for, cria-se a aresta e atribui-se o peso, que é a diferença de intensidade dos pixels em questão, a essa aresta. Isso é repetido para todos os pares de pixels da imagem. Ou seja, se uma imagem tem tamanho  $25 \times 25$  tem-se uma rede com 625 vértices.

---

**Algoritmo 1:** Mapeamento da imagem em rede direcionada regular

---

**Entrada:** Imagem, raio  
**Saída:** Rede direcionada regular

```

1 início
2   grafo ← grafo()
3   para cada i em  $p_i \in P$  faça
4     para cada j em  $p_j \in P$  faça
5       se  $dist(i, j) \leq \sqrt{r}$  então
6         peso ←  $I(i) - I(j)$ 
7         aresta(i, j) ← peso
8         grafo ← aresta(i, j)
9       senão
10        continue
11      fim
12    fim
13  fim
14 fim
```

---

A rede obtida é um grafo regular, pois os vértices possuem o mesmo número de conexões. O próximo passo é aplicar um conjunto de operações para transformar a rede obtida até o momento em uma rede complexa.

Afim de revelar as propriedades da textura da imagem, é aplicada uma função sobre as ligações da rede que consiste na seleção de aresta de acordo com o peso. As ligações  $e_{v_i, v_j}$  que são mantidas na rede, são definidas pela Equação 4.2. Nessa equação,  $t$  indica um valor de limiar que irá gerar uma versão escalonada da rede.

$$e_{v_j, v_i} = \begin{cases} e_{v_i, v_j}, & \text{se } 0 < e_{v_i, v_j} \leq t \\ NaN, & \text{caso contrário} \end{cases} \quad (4.2)$$

Considera-se a função do limiar como uma análise de rede em múltiplas escalas (GONÇALVES et al., 2016), que transforma uma rede regular em um rede com menos arestas. Essa

rede é chamada de rede escalonada (Figura 11). Com a variação do limiar  $t$ , é gerado um conjunto  $T = t_1, t_2, \dots, t_n$ , onde para cada valor de  $t_i$  uma rede  $t$ -escalonada é criada. Com isso, diferentes limiares são utilizados para conseguir uma análise mais completa da rede. Em comparação com a rede normal, uma rede  $t$ -escalonada apresenta propriedades diferentes e revela a estrutura e a topologia relacionadas à sua escala. A Figura 11 mostra as redes depois de aplicado a função do limiar.

Para valores pequenos de  $t_i$ , a rede captura detalhes da imagem relacionados com pequenos conjuntos de pixels, à medida que  $t_i$  aumenta, a rede expressa informações globais da imagem, como as bordas dos objetos (Figura 11). Mais detalhes sobre este tipo de mapeamento da imagem em um conjunto de redes, e sobre como se dá a escolha dos valores de  $t_i$ , podem ser entendidos no trabalho de Gonçalves et al. (2016).




Figura 11 – Exemplo de redes escalonadas para diferentes valores de limiar. **Fonte:** (GONÇALVES et al., 2016)

Após o mapeamento das imagens com redes complexas é necessário caracterizá-las de forma robusta e eficiente. Essa caracterização pode ser realizada por meio das diversas medidas propostas para redes complexas (e.g. média do grau dos vértices, coeficiente de aglomeração). Entretanto, a medida de centralidade *closeness* tem apresentado um alto desempenho e aplicabilidade na resolução de diversos problemas.

Dessa forma, após a obtenção do conjunto das redes escalonadas que foram definidas por diferentes valores de limiar  $t_i$ , aplicou-se o *closeness* nessas redes, gerando assim, uma matriz  $D_{t_i}$  para cada uma das redes. A Figura 12 mostra os seis padrões radiográficos depois de aplicada a medida de centralidade *closeness*. A medida que os valores de limiar crescem a rede captura mais detalhes da textura da imagem. E também, à medida que o  $t_i$  aumenta, mais links na rede são mantidos e, portanto vão aparecendo mais vértices com alto valor de centralidade, resultando em uma imagem com mais detalhes na textura.




Figura 12 – Exemplos da aplicação da medida de centralidade *closeness* nos seis padrões radiográficos. A rede foi escalonada com valores de  $t = 30, 150, 270$  e raio fixo  $r = \sqrt{5}$ .  
**Fonte:** Autor.



## 4.2 Definição de um Vetor de Características

Conforme observado na seção anterior, os valores de centralidade dos vértices incorporam informações importantes sobre a textura. Para agrupar essa medida, é proposto um vetor de características composto pela relação dos níveis de cinza da imagem e os valores obtidos pela medida de centralidade *closeness*.

Antes de gerar o vetor de características, calcula-se a média dos valores da centralidade obtidos em todas as matrizes  $D_{t_i}$ , gerando assim uma única matriz  $D$  para cada imagem. Após a obtenção de  $D$ , objetivando gerar o vetor de características, é realizada uma análise quanto a relação entre os níveis de cinza da imagem e os valores obtidos com *closeness*. Para tanto, verifica-se o nível de cinza do pixel  $p_i$ . Caso este nível esteja no intervalo  $w < I(p_i) \leq z$  então, o valor do *closeness* no vértice referente ao pixel  $p_i$  é somado com os demais valores de *closeness* dos pixels com a mesma intensidade do pixel  $p_i$  e que estavam no mesmo intervalo. A equação a seguir (4.3) mostra essa relação.

$$S_{w_n, z_n} = \begin{cases} CC(i), & \text{se } w < I(p_i) \leq z \\ NaN, & \text{caso contrário} \end{cases} \quad (4.3)$$

Para cada imagem tem-se o seguinte vetor:

$$\varphi^n = [S_{w_1, z_1}, S_{w_2, z_2}, S_{w_3, z_3}, \dots, S_{w_n, z_n}]$$

onde  $n$  é a quantidade de imagens existentes na base de dados.

O vetor de características com os valores da medida de centralidade é criado concatenando os vetores  $\varphi^n$ :

$$\varphi = [\varphi^1, \varphi^2, \varphi^3, \dots, \varphi^n]$$

Além das características extraídas pelo método proposto, percebeu-se a necessidade de extrair mais informações globais da imagem. Para tanto, escolheu-se o LBP e os descritores de Haralick, que são dois métodos clássicos da literatura e que conseguem descrever bem as texturas das imagens. Dessa forma, aplicou-se os dois métodos nas imagens de tomografia com DPIs e juntou-se com as características do método proposto, criando um vetor  $V$  que contém as informações de todas as imagens. O vetor de características final será utilizado em um processo de classificação. O método de classificação utilizado e a acurácia obtida estão descritos no próximo Capítulo (Cap. 5).

## 5 RESULTADOS E DISCUSSÃO

A base de dados utilizada nesse trabalho foi retirada de um banco de dados contendo 247 imagens de tomografia com DPIs, selecionadas por um grupo de radiologistas, de 108 diferentes exames realizados no Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto da Universidade de São Paulo (HCFMRP - USP).


Dessas 247 imagens, foram selecionados 3.258 ROIs (*Regios Of Interest*), cada um com tamanhos  $64 \times 64$  pixels. Esses ROIs foram agrupados em categorias de acordo com o relato radiológico e o padrão radiográfico presente e são elas: favo de mel, vidro fosco, espessamento septal, consolidação pulmonar, áreas enfisematosas e normal. A Figura 13 ilustra alguns exemplos dos padrões radiográficos que estão presentes na base de dados. Mais detalhes sobre a base de dados podem ser encontrados em Pereyra et al. (2014).

Para realizar a classificação dos dados obtidos, utilizou-se o classificador K-vizinhos mais próximos (*K-Nearest Neighbor* - KNN) com distância Euclidiana e a validação cruzada com 10 subconjuntos. Mais informações sobre o classificador e o esquema de validação cruzada encontram-se no trabalho de Liu e Fieguth (2012). Assim como Gonçalves et al. (2016), escolheu-se um classificador simples para evidenciar a importância dos dados obtidos utilizando o método proposto na tarefa de classificação.

### 5.1 Resultados

Para aplicar a abordagem proposta para a classificação de texturas, utilizou-se os seguintes parâmetros:  $t_0 = 20$ ,  $t_i = 40$ ,  $m = 5$  e  $r = 4$ . Tais valores tratam, respectivamente, de um limiar inicial, um incremento sobre o valor atual do limiar, o número de vezes que o limiar é incrementado e o raio que define a vizinhança de um vértice  $v_i$ . Esses parâmetros foram escolhidos com base em experimentos realizados para encontrar valores que melhor descrevessem as imagens de tomografia com DPIs (ver detalhes sobre estes parâmetros e como realizar os experimentos em Gonçalves et al. (2016)). Na classificação, foram realizadas 100 repetições para obter a média da acurácia obtida pelo KNN. Para validar os dados, utilizou-se a técnica de validação cruzada *k-fold* com 10 *folds*.


Os experimentos foram executados em uma máquina com processador Core i3, 4GB de memória RAM e Sistema Operacional GNU/Linux Ubuntu 18.04.1 LTS. Não foram utilizados recursos de GPU neste processo. O algoritmo foi implementado na linguagem de programação *Python*, usando pacote *graph-tool* para gerar os grafos e para calcular a métrica de centralidade *closeness*. Com esses recursos computacionais, necessitou-se de, em média, 7 horas e 30 minutos para executar o algoritmo do método proposto em todas as imagens da base de dados. O algoritmo do *closeness* do *graph-tool* tem complexidade computacional de  $O(V(V + E))$ , onde  $V$  é o número de vértices e  $E$  o número de arestas da rede.




(a) Imagem normal




(b) Consolidação




(c) Enfisema



(d) Espessamento



(e) Favo de mel



(f) Vidro fosco

Figura 13 – Exemplos de imagens com DPIs que estão na base de dados

Com esses parâmetros e recursos, obteve-se uma taxa de classificação de 79.79% no conjunto de dados gerado pelo método utilizando o *closeness* sem considerar a inserção dos descritores de Haralick e LBP no vetor. Com a junção dos três métodos, *closeness*, descritores de Haralick e LBP, obteve-se uma acurácia de 89.81%. Para chegar a esse resultado, realizou-se a junção do vetor de característica final do método com o *closeness* com os métodos LBP e descritores de Haralick de forma individual, a junção dos dois métodos sem o *closeness* e a junção dos três métodos. A Tabela 2 exibe as combinações feitas e quais foram as acurácias obtidas. As acurácias dos métodos LBP e Haralick de forma individual podem ser vistas na Tabela 3.

Métodos	Acurácia
Haralick + LBP	83.75
Closeness + Haralick	83.81
Closeness + LBP	88.35
Closeness + Haralick + LBP	89.81

Tabela 2 – Resultado dos experimentos realizados com a junção dos métodos.

O resultado do método proposto utilizando apenas o *closeness* de forma individual supera os métodos clássicos da literatura: GLCM, LBP e Haralick (Tabela 3). Dessa forma, verifica-se que, utilizando o classificador KNN, os métodos mais tradicionais funcionam de forma mais limitada, enquanto o método proposto consegue descrever de forma mais detalhada a textura das imagens de tomografia com DPIs.

Métodos	N. de features	Acurácia
GLCM	4	66.28
LBP	10	72.87
Descritores de Haralick	14	74.22
Método de Pereyra et al. (2014)	16	82.62
Método de Gonçalves et al. (2016)	132	82.98
<b>Método Proposto</b>	<b>99</b>	<b>89.81</b>

Tabela 3 – Comparação do método proposto com outros métodos.

Como foi observado, experimentalmente, a criação de um histograma composto não apenas de valores resultantes da aplicação da medida de centralidade, mas também com valores resultantes da aplicação dos descritores Haralick e LBP, potencializa ainda mais o método. Com isso, alcançou-se uma taxa de classificação mais alta do que o método de Pereyra et al. (2014) e de Gonçalves et al. (2016), que são métodos mais atuais para extração de textura. O método proposto neste trabalho utilizou a mesma base de dados utilizada por Pereyra et al. (2014), porém o método proposto por eles não obteve uma taxa de classificação mais alta. Isso aconteceu porque eles utilizaram apenas um tipo de abordagem, a estatística. Esse tipo de abordagem não descreve bem a textura das imagens, pois é uma abordagem local. Dessa forma, percebe-se como

o método proposto neste trabalho, que utiliza uma abordagem mista, consegue classificar melhor as imagens com DPIs.

A Tabela 4 exibe a matriz de confusão do KNN. Os padrões radiográficos, que são as classes utilizadas para a classificação, estão representados por letras: A - consolidação, B - enfisema, C - espessamento, D - Favo de mel, E - normal e F - vidro fosco. A matriz de confusão mostra o número de classificações corretas, que se encontram nas linhas, *versus* as classificações preditas, que se encontram nas colunas, para cada classe. Sabendo disso, percebe-se, por exemplo, que o modelo classificou 407 instâncias como classe A e que realmente eram da classe A, e classificou 4 instâncias como classe B, 18 instâncias como classe C, 6 instâncias como classe D, 7 instâncias como classe E e 9 instâncias como classe F, porém, essas instâncias na verdade eram da classe A. O número de acertos, para cada classe dos padrões radiográficos, localiza-se na diagonal principal da matriz. Percebe-se que todas as classes têm uma taxa de classificação correta acima de 80%, sendo a classe A (consolidação) com a maior taxa de acerto e a classe C (espessamento) com a menor.

	A	B	C	D	E	F	Total	Correto	Erro
A	<b>407</b>	4	18	6	7	9	451	90%	10%
B	5	<b>436</b>	12	0	49	0	502	87%	13%
C	39	31	<b>423</b>	39	34	23	590	81%	19%
D	4	27	48	<b>436</b>	5	10	530	82%	18%
E	16	44	19	2	<b>498</b>	11	590	84%	16%
F	31	1	43	8	2	<b>510</b>	595	86%	14%
Correto	<b>407</b>	<b>436</b>	<b>423</b>	<b>436</b>	<b>498</b>	<b>510</b>	<b>3.258</b>	<b>89.10%</b>	<b>10.90%</b>

Tabela 4 – Matriz de confusão com o resultado da classificação do KNN.

Pereyra et al. (2014) descrevem essa doença como tendo uma classificação consistentemente ruim, mas o método proposto nesse trabalho melhora a taxa de classificação em mais de 6% em relação aos resultados anteriores. E com isso, percebe-se que as transformações realizadas nas redes complexas e a medida de centralidade *closeness* auxiliam na caracterização das texturas nas imagens de tomografia com DPIs.

## 6 CONCLUSÃO

As Redes Complexas possuem um alto nível de modelagem que abrangem desde as interações entre células até as mais complexas redes sociais. Na maioria das vezes, o estudo dos elementos da rede não é suficiente para determinar o comportamento modelado. Com isso, a extração de informações topológicas e estruturais dessas redes é de extrema importância para aplicações reais, como por exemplo, na extração de características de textura de imagens.

A textura pode ser vista como um conjunto de determinados padrões existentes nos objetos e que trazem grande quantidade de informações sobre eles. A classificação correta de qualquer textura depende muito dos descritores utilizados para caracterizá-la.

Neste contexto, este trabalho propôs uma abordagem que extrai características da textura das imagens de tomografia com DPIs, mapeando as imagens em redes direcionadas. Para isso, considerou-se cada pixel como um vértice da rede e conectando vértices dentro de um determinado raio. Depois da rede formada e escalonada, aplicou-se a medida de centralidade *closeness* e formou-se um vetor de características com a soma das centralidades que estavam dentro de um determinado intervalo.

A partir das análises dos resultados, conclui-se que o método proposto consegue descrever a textura das imagens. De forma individual, conseguiu-se uma acurácia acima dos métodos tradicionais, e com a junção dos métodos LBP e descritores Haralick foi possível subir ainda mais a taxa de classificação, com uma acurácia acima dos métodos atuais. O aumento da acurácia com a junção dos métodos se deu por causa da boa representatividade que o LBP e descritores Haralick tem em extrair informações, de forma global, nas imagens. Dessa forma, afirma-se que o método proposto, tem grande representatividade na extração de características de textura de imagens, mais especificamente nas imagens com DPIs, que são doenças que têm uma classificação consistentemente ruim.

Os bons resultados obtidos pelo método sugerem que novos trabalhos podem ser gerados. O método proposto pode ser estendido e ser aplicado em imagens coloridas ou em outros tipos de imagens médicas, como imagens de endoscopia, colonoscopia, angiografia. Além disso, o método pode ainda ser aplicado em outros problemas de Visão Computacional, como por exemplo, restauração de imagens com borramento, reconhecimento de textura em vídeos, dentre outros.

## REFERÊNCIAS

- ALEXANDRE, T. et al. GistSumm : A Summarization Tool Based on a New. *In 6th Workshop on Computational Processing of the Portuguese Language Written and Spoken -Propor*, 2003.
- ALMEIDA, E.; RANGAYYAN, R. M.; AZEVEDO-MARQUES, P. M. Fuzzy Membership Functions for Analysis of High-Resolution CT Images of Diffuse Pulmonary Diseases \*. *IEEE*, p. 719–722, 2015.
- ALMEIDA, E.; RANGAYYAN, R. M.; AZEVEDO-MARQUES, P. M. Gaussian Mixture Modeling for Statistical Analysis of Features of High-Resolution CT Images of Diffuse Pulmonary Diseases. 2015.
- ANTHIMOPOULOS, M. et al. Classification of Interstitial Lung Disease Patterns Using Local DCT Features and Random Forest. *IEEE*, p. 6040–6043, 2014.
- ANTHIMOPOULOS, M. et al. Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network. *IEEE Transactions on Medical Imaging*, v. 0062, n. c, p. 1–10, 2016.
- ANTIQUERA, L. et al. Modelando Textos como Redes Complexas \*. *XXV Congresso da Sociedade Brasileira de Computação*, p. 2089–2098, 2005.
- BACKES, A. R.; CASANOVA, D.; BRUNO, O. M. A complex network-based approach for boundary shape analysis. *ELSEVIER - Pattern Recognition*, v. 42, p. 54–67, 2009.
- BALDI, B. G. et al. Destaques das diretrizes de doenças pulmonares intersticiais da Sociedade Brasileira de Pneumologia e Tisiologia. *Jornal Brasileiro de Pneumologia*, v. 38, n. 3, p. 282–291, 2012. ISSN 1806-3713.
- BARABASI, A. L. Linked: How everything is connected to everything else and what it means for business, science and everyday life. *Plume*, 2003.
- BENTLEY, P. M.; MCDONNELL, J. T. E. Wavelet transforms: an introduction. *Electronics & Communication Engineering Journal*, v. 6, n. 4, p. 175–186, 1994. ISSN 09540695.
- BHARATI, M. H.; LIU, J. J.; MACGREGOR, J. F. Image texture analysis: Methods and comparisons. *Chemometrics and Intelligent Laboratory Systems*, v. 72, n. 1, p. 57–71, 2004. ISSN 01697439.
- CAPUTO, B.; HAYMAN, E.; MALLIKARJUNA, P. Class-specific material categorisation. In: *Tenth IEEE International Conference on Computer Vision (ICCV'05) Volume 1*. [S.l.]: IEEE, 2005. p. 1597–1604 Vol. 2. ISBN 0-7695-2334-X.
- CARDOSO, I. et al. Evaluation of deep feedforward neural networks for classification of diffuse lung diseases. *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*, v. 10657, p. 152–159, 2018.
- COUTO, L. N.; BACKES, A. R.; BARCELOS, C. A. Z. Texture characterization via deterministic walks' direction histogram applied to a complex network-based image transformation. *Pattern Recognition Letters*, 2017. ISSN 01678655.

CRIMMINS, T. R. A Complete Set of Fourier Descriptors for Two-Dimensional Shapes. *IEEE Transactions on Systems, Man and Cybernetics*, v. 12, n. 6, p. 848–855, 1982. ISSN 21682909.

FERREIRA, J. R.; OLIVEIRA, M. C.; AZEVEDO-MARQUES, P. M. de. Characterization of Pulmonary Nodules Based on Features of Margin Sharpness and Texture. *Journal of Digital Imaging*, p. 1–13, 2017. ISSN 1618727X.

FLICKR. *Electromagnetic spectrum*. 2011. Acessado em: 10 de Novembro de 2018. Disponível em: <<http://www.flickr.com/photos/agathman/5428089105/>>.

FOGEL, I.; SAGI, D. Gabor filters as texture discriminator. *Biological Cybernetics*, v. 61, n. 2, p. 103–113, 1989. ISSN 03401200.

GONÇALVES, W. N. *Caminhadas Determinísticas em Redes Complexas Aplicadas em Visão Computacional*. 104 p. Tese (Doutorado), 2010.

GONÇALVES, W. N. et al. Texture recognition based on diffusion in networks. *Information Sciences*, v. 365, p. 51–71, 2016.

GONZALEZ, R. C.; WOODS, R. E. *Processamento Digital de Imagens*. [S.l.]: Pearson Prentice Hall, 2010.

HARALICK, R.; SHANMUGAN, K.; DINSTEN, I. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, v. 3, 1973.

HATTIKATTI, P. Texture based Interstitial Lung Disease Detection using Convolutional Neural Network. *International Conference on Big Data, IoT and Data Science*, p. 18–22, 2017.

HU, E. et al. Bleeding and tumor detection for capsule endoscopy images using improved geometric feature. *Journal of Medical and Biological Engineering*, Springer Berlin Heidelberg, v. 36, n. 3, p. 344–356, 2016.

HUANG, K. *Statistical mechanics*. [S.l.]: Wiley, John & Sons., 1990. ISBN 0471815187.

JOYSEEREE, R.; MULLER, H.; DEPEURSING, A. Rotation-Covariant Tissue Analysis for Interstitial Lung Diseases Using Learned Steerable Filters: Performance Evaluation and Relevance for Diagnostic Aid. *Computerized Medical Imaging and Graphic*, p. 1–37, 2018.

JÚNIOR, E. A.; YAMASHITA, H. Aspectos básicos de tomografia computadorizada e ressonância magnética. *Revista Brasileira de Psiquiatria*, v. 23, p. 1–3, 2001.

LIU, L.; FIEGUTH, P. Texture Classification from Random Features. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 34, n. 3, p. 574–586, mar 2012. ISSN 0162-8828.

LIU, L. et al. Local binary features for texture classification: Taxonomy and experimental study. *Pattern Recognition*, Elsevier, v. 62, p. 135–160, 2017. ISSN 00313203.

LU, L. et al. Vital nodes identification in complex networks. *Physics Reports*, v. 650, p. 1–63, 2016. ISSN 03701573.

MARTINEZ, J. Doenças intersticiais pulmonares. *Medicina (Ribeirao Preto. Online)*, p. 247–256, 1998.

MARTINS, E. R. d. S. et al. Caracterização de lesões intersticiais de pulmão em radiograma de tórax utilizando análise local de Textura. *Radiologia Brasileira*, v. 38, n. 3, p. 421–426, 2005.



- MATAS, J.; MARIK, R.; KITTLER, J. On Representation and Matching of Multi-Coloured Objects. *IEEE Computer Vision*, p. 726–732, 1995.
- MORRIS, O. J.; LEE, M. D. J. Graph theory for image analysis : an approach based on the shortest spanning tree. *Communications, Radar and Signal Processing, IEE Proceedings*, v. 133, n. 2, 1986.
- NETO, E. C. et al. Segmentação 3D de Fissuras Pulmonares em Imagens de TC Utilizando Texturas. *XXIV Congresso Brasileiro de Engenharia Biomédica – CBEB*, p. 2417–2420, 2014.
- NEWMAN, M. E. J. *Networks: an introduction*. Oxford; New York: Oxford University Press, 2010. ISBN 9780199206650 0199206651.
- OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, v. 29, n. 1, p. 51–59, 1996. ISSN 00313203.
- PEREYRA, L. C. et al. Fractal analysis for computer-aided diagnosis of diffuse pulmonary diseases in HRCT images. *IEEE MeMeA 2014 - IEEE International Symposium on Medical Measurements and Applications, Proceedings*, 2014.
- RIBAS, L. C. *Análise de texturas dinâmicas baseada em sistemas complexos*. Tese (Doutorado) — USP, 2017.
- SCHEINERMAN, E. *Matemática Discreta: uma introdução*. [S.l.]: Thonsom Learning, 2006.
- SEGUÍ, S. et al. Categorization and segmentation of intestinal content frames for wireless capsule endoscopy. *IEEE Transactions on Information Technology in Biomedicine*, v. 16, n. 6, p. 1341–52, 2012.
- SIMON, P.; UMA, V. Review of Texture Descriptors for Texture Classification. *Data Engineering and Intelligent Computing, Advances in Intelligent Systems and Computing 542*, v. 542, p. 159–176, 2018. ISSN 21945357.
- WANG, L.; HE, D.-C. Texture classification using texture spectrum. *Pattern Recognition*, v. 23, n. 8, p. 905–910, 1990. ISSN 0031-3203.
- XU, Y.; UBERBACHER, E. C. 2D image segmentation using minimum spanning trees. *ELSEVIER - Image and Vision Computing*, v. 15, p. 47–57, 1997.
- ZADEH, L. A. Fuzzy Sets. *Information and Control*, 1965.