



RECONHECIMENTO DE PADRÃO EM PACIENTES COM ESCLEROSE
SISTÊMICA POR SISTEMAS *FUZZY*

Fernando Moraes de Oliveira

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia de Sistemas e Computação, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia de Sistemas e Computação.

Orientador: Luis Alfredo Vidal de Carvalho

Rio de Janeiro
Junho de 2017

RECONHECIMENTO DE PADRÃO EM PACIENTES COM ESCLEROSE
SISTÊMICA POR SISTEMAS *FUZZY*

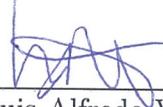
Fernando Moraes de Oliveira

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE)
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR
EM CIÊNCIAS EM ENGENHARIA DE SISTEMAS E COMPUTAÇÃO.

Examinada por:



Prof. Mário Roberto Folhadela Benevides, Ph.D.



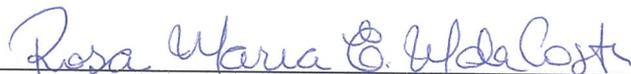
Prof. Luis Alfredo Vidal de Carvalho, D.Sc.



Profª Regina Serrão Lanzillotti, D.Sc.



Prof. Agnaldo José Lopes, D.Sc.



Profª Rosa Maria Esteves Moreira da Costa, D.Sc.

RIO DE JANEIRO, RJ – BRASIL
JUNHO DE 2017

Oliveira, Fernando Moraes de

Reconhecimento de Padrão em pacientes com Esclerose Sistêmica por Sistemas *Fuzzy*/Fernando Moraes de Oliveira. – Rio de Janeiro: UFRJ/COPPE, 2017.

XIV, 74 p.: il.; 29, 7cm.

Orientador: Luis Alfredo Vidal de Carvalho

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia de Sistemas e Computação, 2017.

Referências Bibliográficas: p. 67 – 74.

1. Reconhecimento de Padrão. 2. Processamento de Imagem. 3. Sistemas *Fuzzy*. 4. Esclerose Sistêmica. I. Carvalho, Luis Alfredo Vidal de. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia de Sistemas e Computação. III. Título.

"A fé desempenha em nossa vida um papel mais importante do que supomos, e é o que nos permite fazer mais do que pretendemos.

Creio que aí está o elemento precursor de nossas ideias. Sem a fé não se teria elaborado jamais hipóteses e teorias, nem se teriam inventado as ciências ou as matemáticas. Estou convencido de que a fé é um prolongamento do espírito e negar a fé é condenar-se e condenar o espírito que engendra todas as forças criadoras de que dispomos."

Charlie Chaplin

"Queira! Basta ser sincero e desejar profundo, você será capaz de sacudir o mundo."

Raul Seixas

"Não há sentido em ser exato quando você nem sabe sobre o que está falando."

John Von Neumann

Agradecimentos

Primeiramente à Deus (algo superior ainda incompreendido por mim) que permitiu dia após dia que eu chegasse até esse momento.

Às minhas filhas Maria Fernanda e Juliana que mesmo sem saber por causa da tenra idade são a grande inspiração para que eu continue na busca da realização de todos os meus sonhos. O silêncio ou a inquietação de cada uma delas, ao seu modo, me faz querer ir além.

Aos meus pais e irmãos pela força em absolutamente tudo que me engajei na vida.

Ao querido professor e orientador Luís Alfredo por ter me dado essa grande oportunidade de aprendizado pessoal e profissional, obrigado por acreditar em mim.

À querida professora Regina Lanzillotti que com muito carinho transmitiu-me segurança e me apoiou sem hesitar em todos os momentos turbulentos que atravessei durante esse período, não existem palavras para expressar minha profunda gratidão.

Ao médico e professor Agnaldo Lopes que me apoiou com orientações especializadas, materiais de pesquisa e tudo que foi solicitado sempre com um sorriso no rosto e uma fala mansa tranquilizadora.

Ao presidente da banca examinadora professor Mário Benevides por ter aceito o convite e aos demais membros, que dividiram comigo este momento tão importante e especial.

Ao professor Amit Bhaya do PEE/COPPE por “abrir as portas” do Nacad para que eu pudesse utilizar os equipamentos que auxiliaram no desenvolvimento desta Tese.

Aos servidores públicos lotados na secretaria do PESC/COPPE/UFRJ, em especial ao Gutierrez da Costa, que com muita dedicação exerce sua função transbordando profissionalismo, paciência e principalmente, boa vontade. Muito obrigado por me ajudar em absolutamente tudo que precisei, mesmo muitas vezes não sendo sua função, sinto-me extremamente feliz em saber que existem servidores públicos como você.

Ao IFRJ pelo afastamento concedido, essencial para a conclusão desta Tese.

Aos amigos e amigas que estiveram do meu lado durante essa importante e árdua jornada (não citarei nomes pelo simples fato de não querer ser injusto), o meu muito

obrigado a todXs vocês!

Na disciplina Fatos e Artefatos como Construções Sócio-Técnicas lecionadas à época pelos professores Henrique e Ivan, aprendi entre outras coisas, sobre a Sociologia do Conhecimento, que trata o conhecimento como algo coletivo e totalmente dependente das influências sociais, do mundo à nossa volta, portanto finalizo agradecendo a todas as pessoas que passaram pela minha vida acadêmica/profissional e pessoal, certamente tem um pouco de cada uma delas neste trabalho.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

RECONHECIMENTO DE PADRÃO EM PACIENTES COM ESCLEROSE
SISTÊMICA POR SISTEMAS *FUZZY*

Fernando Moraes de Oliveira

Junho/2017

Orientador: Luis Alfredo Vidal de Carvalho

Programa: Engenharia de Sistemas e Computação

As imagens médicas objetivam captar informações para diagnóstico e/ou acompanhamento do paciente. As tecnologias de aquisição de imagem evoluíram e se apresentam como: tomografia computadorizada (TC), ultrassonografia, ressonância magnética (RMP), medicina nuclear e a radiografia simples (raio-X). As imagens de radiografias simples de tórax possuem invariavelmente gradações de intensidade e incertezas, o que conduz à escolha da abordagem dos sistemas *fuzzy* (SF). Objetiva-se otimizar a visualização de imagens de radiografias simples de tórax na confirmação e acompanhamento do diagnóstico do acometimento pulmonar em pacientes com esclerose sistêmica (ES). O reconhecimento de padrão pela metodologia *fuzzy* com destaque na segmentação das imagens pelos conjuntos intuicionistas *fuzzy* (CIF), conduziu a criação do índice de intensidade de fibrose pulmonar (*IIFP*) pelos conjuntos *fuzzy* (CF) que associado às variáveis advindas dos exames de função pulmonar, capacidade vital forçada (*CVF*) e capacidade de difusão do monóxido de carbono (D_{LCO}), contribuiu para o acompanhamento clínico de pacientes com ES. As técnicas e métodos implementados, propiciou o desenvolvimento do SisRPIP - Sistema de Reconhecimento de Padrão em Imagens Pulmonares. A viabilidade do SisRPIP foi verificada em radiografias simples de tórax de 40 pacientes já diagnosticados com ES e, os resultados, assim como a metodologia utilizada são apresentados nesta Tese.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

PATTERN RECOGNITION IN PATIENTS WITH SYSTEMIC SCLEROSIS BY
FUZZY SYSTEMS

Fernando Moraes de Oliveira

June/2017

Advisor: Luis Alfredo Vidal de Carvalho

Department: Systems Engineering and Computer Science

Medical images are used to gather information for diagnosis and/or follow-up of patients state. Image acquisition technologies have evolved along the years and the most common are: computed tomography (CT), ultrasonography, magnetic resonance imaging (MRI), nuclear medicine and x-ray. Chest X-ray images invariably have intensity gradations and uncertainties, which leads to the choice of the fuzzy systems (FS) approach. The objective of this study was to optimize images of simple chest X-ray that are used in pulmonary involvement diagnoses' confirmation and follow-up in patients with systemic sclerosis (SS). Pattern recognition using fuzzy methodology, with emphasis on the images segmentation by the intuitionist fuzzy sets (IFS), led to the creation of the pulmonary fibrosis intensity index (*PFII*) using fuzzy sets (FS). This index, associated with results from pulmonary function tests (PFT), forced vital capacity (*FVC*) and carbon monoxide diffusion capacity (*D_{LCO}*), assisted on the clinical follow-up of patients with SS. The techniques and methods implemented allowed the development of the SisRPIP - Pattern Recognition System in Pulmonary Imaging. The viability of the SisRPIP was verified with 40 patients' plain chest radiographs already diagnosed with SS, and the results and methodology used, are presented in this thesis.

Sumário

Lista de Figuras	xi
Lista de Tabelas	xiii
1 Introdução	1
1.1 Objetivo	3
1.1.1 Geral	3
1.1.2 Específico	3
1.2 Justificativa	4
1.3 Contribuições originais	6
1.4 Organização do trabalho	6
2 Esclerose Sistêmica	7
3 Metodologia	10
3.1 Processamento de Imagem	10
3.2 Aquisição e digitalização da imagem	10
3.3 Pré-processamento	12
3.4 Segmentação	13
3.4.1 Segmentação pelo método de Otsu	15
3.4.2 Segmentação pelos conjuntos intuicionistas <i>fuzzy</i>	19
3.5 Classificação do acometimento da fibrose pulmonar sob a ótica dos conjuntos <i>fuzzy</i>	22
4 Resultados	33
4.1 Segmentação por Otsu	34
4.2 Segmentação pelo conjunto intuicionista <i>fuzzy</i>	46
4.3 Validação dos métodos implementados ao reconhecer padrão do acometimento pulmonar	59
4.3.1 Afinidade pelo método de Otsu entre <i>IIFP</i> , <i>CVF</i> e D_{LCO}	59
4.3.2 Afinidade pelos conjuntos intuicionistas <i>fuzzy</i> entre <i>IIFP</i> , <i>CVF</i> e D_{LCO}	62

5	Considerações Finais	65
	Referências Bibliográficas	67

Lista de Figuras

1.1	Radiografia simples de tórax.	5
3.1	Passo à passo das etapas do scanRX.	11
3.2	Conjunto <i>fuzzy</i> trapezoidal triangular.	13
3.3	Esquema da etapa de pré-processamento para ajuste da imagem.	13
3.4	Exemplo de histograma de uma imagem.	15
3.5	Representação gráfica das premissas do método de Otsu.	17
3.6	Representação gráfica do limiar ótimo pelo método de Otsu.	18
3.7	Esquema de segmentação pelo método de Otsu.	19
3.8	Esquema de segmentação sob a ótica dos conjuntos intuicionistas <i>fuzzy</i>	22
3.9	Conjunto <i>fuzzy</i> triangular.	23
3.10	Conjunto <i>fuzzy</i> de uma imagem digital de 2^8 bits.	24
3.11	Conjunto <i>fuzzy</i> do <i>IIFP</i>	26
3.12	Conjuntos <i>fuzzy</i> da <i>CVF</i> e <i>D_{LCO}</i>	27
3.13	Esquema executado nesta Tese.	32
4.1	Tela inicial do SisRPIP.	34
4.2	Tela inicial do SisRPIP quando selecionada a imagem.	34
4.3	Imagem original e pré-processada e os respectivos histogramas.	35
4.4	Imagem binarizada pelo método de Otsu.	36
4.5	Código para armazenamento da efetividade do método.	36
4.6	Código para visualização do limiar pelo método de Otsu.	37
4.7	Segmentação personalizada pelo especialista.	37
4.8	Código implementado em Matlab®2015a para o pulmão esquerdo.	38
4.9	Tela do SisRPIP com o valor do <i>IIFP</i> , a classificação <i>fuzzy</i> e sua respectiva pertinência.	38
4.10	Código implementado em Matlab®2015a para o pulmão esquerdo.	47
4.11	Imagem binarizada pelos conjuntos intuicionistas <i>fuzzy</i>	47
4.12	Segmentação personalizada pelo especialista.	48
4.13	Tela do SisRPIP com o valor do <i>IIFP</i> , a classificação fuzzy e sua respectiva pertinência.	48

4.14	Implementação no Matlab®R2015a para cálculo da entropia dos conjuntos intuicionistas <i>fuzzy</i>	57
4.15	Gráfico de dispersão do <i>IIFP</i> x <i>CVF</i> e <i>IIFP</i> x <i>D_{LCO}</i> com <i>IIFP</i> pelo método de Otsu.	61
4.16	Gráfico de dispersão do <i>IIFP</i> x <i>CVF</i> e <i>IIFP</i> x <i>D_{LCO}</i> com <i>IIFP</i> sob a ótica dos CIF.	64

Lista de Tabelas

3.1	Máquina inferencial <i>fuzzy</i> do <i>IIFP</i> x <i>CVF</i>	30
3.2	Máquina inferencial <i>fuzzy</i> do <i>IIFP</i> x D_{LCO}	31
4.1	Elementos para cálculo do grau de nebulosidade dos conjuntos <i>fuzzy</i> do <i>IIFP</i>	38
4.2	Síntese dos resultados do método de Otsu.	40
4.3	Síntese dos resultados do método sob a ótica dos conjuntos intuicionistas <i>fuzzy</i>	48
4.4	Síntese dos resultados do cálculo da entropia.	55
4.5	Elementos para cálculo do grau de nebulosidade dos conjuntos <i>fuzzy</i> do <i>IIFP</i> sob a ótica dos conjuntos intuicionistas <i>fuzzy</i>	57
4.6	Pertinências e pertinências ponderadas utilizadas para o cálculo da concordância atribuída a Bland Altman com <i>IIFP</i> pelo método de Otsu.	59
4.7	Pertinências e pertinências ponderadas utilizadas para o cálculo da concordância atribuída a Bland Altman com <i>IIFP</i> sob a ótica dos CIF.	62

Lista de Quadros

2.1 Critérios diagnósticos para a esclerose sistêmica [1].	7
--	---

Capítulo 1

Introdução

Cada vez mais, a Medicina vem sendo beneficiada com o uso das Tecnologias da Informação e Comunicação (TIC). As imagens médicas auxiliam especialistas na avaliação de funções e estruturas humanas procurando preservar a saúde dos pacientes e objetivam dar informações necessárias para o diagnóstico das condições do indivíduo e/ou acompanhar sua evolução a uma determinada terapia. Entre as diversas formas de imagens médicas, destacam-se os exames de radiografia simples (raio-X), tomografia computadorizada (TC), ultrassonografia, ressonância magnética (RM) e a medicina nuclear. Apesar de existirem diversas aplicações para processamento computacional de imagens, ainda há uma gama de problemas e soluções a serem resolvidos e aplicados nesta área [2]

Esclerose sistêmica (ES) é uma doença autoimune e crônica do tecido conjuntivo caracterizada por fibrose cutânea e visceral, ativação celular imune e obliteração vascular de pequenas artérias e capilares [3]. É uma condição rara com uma prevalência estimada em 10 casos a cada 100.000 habitantes e uma incidência que varia entre 0,3 e 2,8 casos a cada 100.000/ano, sendo que quase 90% dos casos ocorrem em mulheres [4]. A ES pode acometer diversos órgãos e sistemas, sendo a pele o local mais frequentemente afetado, seguido dos pulmões, sistema musculoesquelético, rim, coração e trato gastrointestinal [5]. O envolvimento do sistema respiratório ocorre em 70% a 90% dos pacientes com ES, sendo a doença pulmonar intersticial e a hipertensão arterial pulmonar as manifestações mais frequentes e com maiores repercussões clínicas [4] [5]. As alterações pulmonares representam atualmente a principal causa de morte em pacientes com ES [4]. Dentre os métodos de investigação do acometimento pulmonar da ES, a biópsia pulmonar raramente é realizada por se tratar de um exame invasivo e, assim, a tomografia computadorizada de alta resolução (TCAR) é considerada atualmente o método de escolha [6]. Uma vez que o uso frequente de radiação ionizante é uma questão de crescente preocupação, a TCAR só raramente é utilizada no seguimento desses pacientes. De fato, a gravidade do comprometimento pulmonar relacionado à ES é mais frequentemente quantificada

e acompanhada na prática clínica rotineira usando a radiografia simples de tórax e os testes de função pulmonar (TFP) [7]. Dentre esses últimos, destacam-se as medidas da capacidade vital forçada (CVF) e da capacidade de difusão ao monóxido de carbono (D_{LCO}) [6].

Diferentes métodos de processamento, segmentação e extração de características de uma imagem digital são frequentemente utilizados na área médica. No processamento de imagem em níveis de cinza, como é o caso da radiografia simples de tórax, o importante é selecionar um limiar adequado para extrair objetos de seu plano de fundo. Nos histogramas das imagens, pode-se visualizar a ocorrência de depressões (vales) entre dois picos que podem vir a representar objeto e fundo, respectivamente, de modo que o limiar pode ser escolhido no fundo desta depressão (vale). Otsu (1979) [8] apresentou um método não paramétrico e não supervisionado de seleção automática de limiar para segmentação de imagem que abordou esta característica. No método em questão, um limiar ótimo é selecionado pelo critério discriminante de modo a maximizar a divisão das classes resultantes. Desde então, diversos trabalhos utilizaram ou testaram a validade do método de Otsu para segmentação de imagens, mais recentemente [9] [10] [11] [12] [13] [14] [15] [16].

A alternativa da abordagem *fuzzy* na análise de imagens é lidar e manusear incertezas e graduações de intensidade que invariavelmente existem em imagens de radiografias simples de tórax [17]. Apesar dessa estratégia não levar em consideração as imprecisões das escalas cromáticas nos objetos adquiridos através dessas imagens, tem ocorrido um progresso significativo em relação à visualização efetiva, manipulação e análise de informações relacionadas aos objetos capturados através de imagens multidimensionais [18].

Muitos algoritmos clássicos para segmentação estão disponíveis na literatura, [19] [20] [21] [8] [22] [23], entretanto nenhum desses algoritmos se propõe a segmentar uma imagem com elementos imprecisos. Após a introdução da metodologia *fuzzy* atribuída a Zadeh (1965) [24], isso deixou de ser um óbice, pois pode ser usada para resolver problemas de segmentação em imagens nebulosas.

Conjuntos *fuzzy* têm sido utilizados com sucesso na área médica [25], em especial na área de processamento de imagem e reconhecimento de padrão [26]. A ideia principal por trás da segmentação por sistemas *fuzzy*, inicia-se pelo processo de fuzzificação da imagem selecionada e posteriormente pela otimização de uma medida *fuzzy* global ou local para atingir a meta de segmentação ideal da imagem, encontrando o melhor limiar para segmentação do fundo e do objeto.

Um método abrangente para construção da função de pertinência foi desenvolvido e pode ser utilizado em algoritmos *fuzzy* para segmentação de imagens [27] e são construídas de maneira que mostram a intensidade do pixel e a intensidade média do objeto e do fundo. Diversos autores já trabalharam com segmentação de

imagens baseada nos conjuntos *fuzzy* [28] [29] [30], entretanto uma das principais questões em aplicar a metodologia *fuzzy* a uma imagem é a forma de obter a função de pertinência adequada que consiga retratar as informações contidas na imagem. A adequação da função de pertinência dependerá sempre das características específicas de cada imagem. De uma forma geral, a maioria dos especialistas usam uma única função de pertinência para representar toda a imagem e um dos problemas desta abordagem reside na dificuldade de designar quais pixels pertencem ao fundo ou ao objeto. Outra questão surge na determinação adequada da função de pertinência que seja peculiar para o desempenho do algoritmo. Dessa forma, há uma hesitação que emerge devido ao conhecimento limitado do usuário no empirismo ao buscar a função de pertinência. Para superar essas questões, conjuntos intuicionistas *fuzzy* (CIF) [31] têm sido cada vez mais utilizados para minimizar a incerteza na seleção da função de pertinência que se adapte à segmentação de imagens [32] [33] [26] [34] [35]. Os CIF são capazes de remover incertezas em maior extensão do que quando se opta por conjuntos *fuzzy* [36], neste sentido, nesta Tese, utilizou-se um método consubstanciado nos CIF, uma vez que trata conjuntamente da função de pertinência e da função de não pertinência.

A viabilidade dos algoritmos sob a visão dos sistemas *fuzzy* (SF) foi efetivada utilizando imagens de radiografia simples de tórax e dados dos TFP, *CVF* e *D_{LCO}*, de 40 pacientes, cedidas pelo Departamento de Pneumologia do Hospital Universitário Pedro Ernesto da Universidade do Estado do Rio de Janeiro, salvaguardando conceitos éticos e legais.

1.1 Objetivo

1.1.1 Geral

Otimizar a visualização de imagens radiográficas simples de tórax na confirmação e/ou acompanhamento clínico do acometimento pulmonar em pacientes diagnosticados com esclerose sistêmica (ES) através do sistema computacional SisRPIP – Sistema de reconhecimento de padrão em imagens pulmonares.

1.1.2 Específico

- Realizar o ajuste da imagem de radiografia simples de tórax digitalizada na etapa de pré-processamento para normalizar a distribuição de frequência;
- Segmentar imagens de radiografias simples de tórax digitalizadas e pré-processadas de pacientes com ES pelo princípio de extensão *fuzzy*;

- Segmentar imagens de radiografia simples de tórax digitalizadas e pré-processadas de pacientes com ES pelo método clássico de Otsu para confronto com o método intuicionista *fuzzy*;
- Propor Índice de Intensidade de Fibrose Pulmonar (*IIFP*) em função da segmentação pelo especialista após a binarização da imagem segmentada como suporte para os conjuntos *fuzzy*;
- Classificar as variáveis capacidade vital forçada (*CVF*) e capacidade de difusão do monóxido de carbono (*D_{LCO}*) dos exames de função pulmonar em função dos conjuntos *fuzzy*;
- Sistema lógico de inferência *fuzzy* na comparação da *CVF* e *D_{LCO}* associadas ao *IIFP*; e,
- Reconhecer padrão do acometimento pulmonar em pacientes com ES.

1.2 Justificativa

A opção por imagens de radiografia simples de tórax (raio-X) nesta Tese, justifica-se por ser uma forma de visualização que mais se aproxima da prática clínica do dia-a-dia do médico nos hospitais e até mesmo no consultório. O baixo custo e a facilidade de aquisição desse tipo de imagem reforçam esta escolha, principalmente porque contribui sobremaneira para o diagnóstico e acompanhamento da evolução da esclerose sistêmica (ES) quando a doença acomete o pulmão.

Raios-X são emissões eletromagnéticas de natureza semelhante à luz visível. Descoberto pelo físico alemão Wilhelm Conrad Rontgen, a primeira radiografia foi feita em 1895. Recebeu este nome por ser um tipo de radiação desconhecido na época. A aplicação para a visualização do interior do corpo humano foi reconhecida quase que imediatamente e é, até hoje, um dos meios mais usados para aquisição de imagens médicas. Apresenta-se como uma forma de radiação eletromagnética de elevada energia e que, ao penetrar o corpo humano, forma uma imagem em algum meio sensível ao raio-X. As estruturas do corpo humano que são mais densas como os ossos, por exemplo, aparecem no filme em branco. O ar e estruturas da mesma densidade aparecem em preto e as outras estruturas aparecem em gradientes de cinza de acordo com o seu grau de absorção dos raios-X [2].

A quantidade de energia transmitida através do meio biológico deve ser convertida para algo perceptível ao ser humano. Para a melhor qualidade de imagem, a configuração do equipamento também deve ser otimizado para obter a melhor resolução e contraste para o tecido de interesse e ao mesmo tempo minimizar os danos por radiação ao paciente. Na realização de um exame de radiografia simples de tórax,

os riscos de radiação são bem reduzidos porque há um monitoramento e regulagem mínima da quantidade de exposição necessária para se produzir a imagem.

As estruturas que melhor se adaptam a avaliação com o raio-X pelo nível de definição da imagem são os ossos e os pulmões. A penetração na anatomia depende das características dos tecidos atingidos, sendo que o contraste entre objetos de interesse é de enorme importância para a detecção de detalhes na imagem e é altamente dependente das características do filme utilizado na aquisição.

Após a exposição do paciente ao raio-X é gerada uma imagem de alto contraste em escala de cinza, podendo ser otimizada na fase de digitalização e pré-processamento que será abordado na seção 3.2 e 3.3. Essa otimização se propõe a solucionar a possível falta de qualidade da imagem durante a realização do exame, pois aumentar a força do sinal do raio-X conduz ao aumento do risco de dano ao DNA pela radiação [2]. Uma forma de exemplificação está na visualização da Figura 1.1 que corresponde a uma radiografia simples de tórax, onde se pode visualizar, a partir da base do pulmão, várias colorações brancacentas que se prolongam para as extremidades do órgão, o que leva a crer que há acometimento pulmonar.



Figura 1.1: Radiografia simples de tórax.

O processamento de imagens computacionais tem colaborado na evolução das técnicas baseadas em imagens médicas. Existem diversas aplicações para processamento, segmentação, cálculo de medidas, reconhecimento de padrões, entre outras, mas ainda assim existe um campo de pesquisa fértil neste contexto [2].

O alto custo e o risco da exposição do paciente à radiação na investigação do acometimento pulmonar pela esclerose sistêmica (ES) em função da tomografia computadorizada de alta resolução (TCAR), que muitas vezes não está disponibilizada à

demanda em hospitais públicos, são fatores que justificam a utilização da radiografia simples de tórax. Cabe ressaltar que a radiografia simples de tórax é mais acessível nos serviços de pronto-atendimento em função da disponibilidade do equipamento e custo reduzido.

A proposta é um sistema lógico de inferência *fuzzy* na associação da imagem com exames de função pulmonar, que propicia o acompanhamento clínico e agiliza a tomada de decisão do especialista.

1.3 Contribuições originais

Utilização de radiografia simples de tórax digital em substituição a tomografia computadorizada para investigação do acometimento pulmonar pela esclerose sistêmica (ES) otimizando o custo operacional e risco da exposição do paciente à radiação.

Confronto do método clássico de segmentação de imagens em tons de cinza de Otsu [8] com método de segmentação proposto sob a ótica dos conjuntos intuicionistas *fuzzy* [31].

Construção do índice de intensidade de fibrose pulmonar (*IIFP*) a partir da radiografia simples de tórax digital após a etapa de segmentação e binarização da imagem.

Associação do *IIFP* com a *CVF* e D_{LCO} , variáveis advindas dos exames de função pulmonar e validação das pertinências das mesmas pela análise de concordância para o intervalo de confiança de Bland Altman [37].

Criação do sistema especialista baseado em inteligência artificial (IA) - SisRPIP - que propicia o reconhecimento de padrão do acometimento pulmonar em pacientes com esclerose sistêmica a partir da radiografia simples de tórax digital e de exames de função pulmonar na tomada de decisão clínica como ferramenta eficaz para o acompanhamento da evolução da doença.

1.4 Organização do trabalho

A seguir, o Capítulo 2 descreve sobre a esclerose sistêmica (ES) e suas características. No Capítulo 3, explana-se sobre a metodologia utilizada nesta Tese. No Capítulo 4, apresenta-se os resultados dos experimentos e no Capítulo 5 procedeu-se as considerações finais.

Capítulo 2

Esclerose Sistêmica

A esclerose sistêmica (ES) é uma doença inflamatória crônica caracterizada por manifestações ligadas à fibrose e disfunção vascular da pele e dos órgãos internos. Acredita-se que sua prevalência é estimada em 10 casos a cada 100.000 habitantes.

O Colégio Americano de Reumatologia juntamente com a Liga Europeia Contra o Reumatismo (American College of Rheumatology/European League Against Rheumatism) determinaram os critérios para o diagnóstico da ES que são baseados nas características clínicas apresentadas pelos pacientes, agregando-se uma pontuação hierárquica que pode ser verificado no Quadro 2.1 [39]. Caso um paciente apresente “Espessamento da pele dos dedos das duas mãos que se estendem proximalmente para as articulações metacarpofalangeanas”, por exemplo, alcançaria pontuação suficiente para que o diagnóstico fosse considerado definitivo, não havendo necessidade de levar em consideração os demais critérios.

Quadro 2.1: Critérios diagnósticos para a esclerose sistêmica [1].

Itens	Subitens	Score
Espessamento da pele dos dedos das duas mãos que se estendem proximalmente para as articulações metacarpofalangeanas		9
Espessamento da pele dos dedos	Dedos “inchados”	2
	Esclerodactilia (metacarpofalangeanas / interfalangeanas)	4
Lesões na ponta dos dedos	Úlceras de poupas digitais	2
	Cicatrizes nas pontas dos dedos	3
Telangiectasias		2
Capilares das cutículas anormais		2
Hipertensão arterial pulmonar e/ou doença pulmonar intersticial	Hipertensão arterial pulmonar	2
	Doença pulmonar intersticial	2
Fenômeno de Raynaud		3
Auto-anticorpos relacionados com a ES	Anti-centrômeros	3
	Anti-topoisomerase I	
	Anti-RNA polimerase III	

Em 1988, LeRoy et al., como resultado de uma extensa análise de todos os modelos de classificação da ES, propuseram o modelo de classificação da ES em duas

formas clínicas: “limitada” e “difusa”.

A forma limitada apresenta envolvimento cutâneo restrito às extremidades (até cotovelos e joelhos, e face), ritmo lento de acometimento cutâneo, presença de calcinose, contraturas articulares pouco frequentes e incidência tardia de manifestações viscerais. Já a forma difusa cursa com envolvimento cutâneo generalizado que afeta tronco, face e membros e apresenta tendência à rápida progressão das alterações cutâneas, contraturas articulares, crepitação tendínea e comprometimento visceral precoce (fibrose pulmonar, miocardiosclerose e crise renal). A forma clínica dita “intermediária” apresenta características clínicas ora de ES limitada ora de ES difusa, não constituindo uma forma clínica específica da ES, razão pela qual foi excluída da classificação atual [40].

Com a proposição desses novos critérios para ES, o prenúncio da doença foi consideravelmente aumentado, permitindo o diagnóstico precoce de um número significativo de pacientes. Existe atualmente uma variada gama de manifestações cutâneas, vasculares e viscerais da ES [41].

Outro aspecto importante da ES é que seu tratamento está baseado em estratégias órgão-específicas, já que cada manifestação clínica pode precisar de uma medicação diferente e específica.

O pulmão é o segundo órgão visceral mais acometido na ES. Atualmente, as manifestações pulmonares são a principal causa de morte nessa doença [42]. A avaliação da queixa de dispneia em pacientes com ES deve incluir a realização de testes de função pulmonar e radiografia simples de tórax, além de outros exames complementares [38].

Sabe-se que mais de 60% dos pacientes vão apresentar alguma forma de lesão pulmonar ao longo da evolução ES, sendo o comprometimento intersticial e a doença vascular pulmonar as mais importantes, pela frequência e maior repercussão clínica [43].

Cerca de 75% dos pacientes com ES têm alterações nos testes de função pulmonar. Destes, aproximadamente 27% apresentam distúrbio ventilatório restritivo moderado [$50\% < \text{capacidade vital forçada (CVF)} < 75\%$ do previsto] e 13% têm distúrbio ventilatório restritivo grave ($\text{CVF} < 50\%$ do previsto) [42].

Estudos que utilizaram a radiografia simples de tórax para a avaliação de fibrose pulmonar relacionada à ES revelaram alterações em 25% a 44% dos casos [44].

Azevedo et al., em 2005, observaram alterações na radiografia simples de tórax em 53% dos pacientes pesquisados. Outros estudos realizados através da avaliação por esse método de imagem também mostraram baixa prevalência do envolvimento pulmonar na ES [42] [45] [46].

Percebe-se que o método de investigação da ES através da radiografia simples de tórax carece de estudos para sua melhoria, principalmente no que tange à visu-

alização da “área doente”. Isto ocorre devido à baixa sensibilidade do método em mostrar alterações pulmonares, principalmente em estágios iniciais da doença.

Nesta Tese, pretendeu-se reconhecer padrões em radiografias simples de tórax digitais de pacientes diagnosticados com ES visando a melhoria da visualização pelo especialista. Isto possibilitou a investigação do acometimento da ES pela identificação da área afetada por fibrose através do índice de intensidade de fibrose pulmonar (*IIFP*), criado à partir desta Tese e permitiu a classificação do paciente através dos exames realizados para aferição da função pulmonar, principalmente os valores relacionados à capacidade vital forçada (*CVF*) e capacidade de difusão do monóxido de carbono (*D_{LCO}*). Como parte do estudo, verificou-se ainda a associação entre o *IIFP*, *CVF* e *D_{LCO}*, ou seja, o quanto a imagem radiográfica simples de tórax digital está relacionada com os exames de função pulmonar.

Capítulo 3

Metodologia

3.1 Processamento de Imagem

Processamento de imagens digitais em duas dimensões vem sendo utilizado desde os anos 60 [47]. Do mesmo modo, conceitos de espaço contínuo (conjuntos de pontos), vizinhança, conectividade, curvas, limites e distância têm sido disponibilizados [48].

As técnicas de processamento de imagens digitais podem ser classificadas quanto ao seu escopo, que se refere à abrangência ou ao seu resultado que está relacionado com o que se deseja obter de cada técnica. A qualidade da imagem a ser analisada é comum nestas duas classes sob a ótica da fidelidade e inteligibilidade. A fidelidade preocupa-se em aproximar a imagem processada da original ou de um padrão estipulado que a represente melhor e a inteligibilidade preocupa-se com a informação que se pode extrair da imagem [49].

O processamento de imagens médicas revolucionou o campo das Ciências Médicas, fornecendo novos métodos para extrair e visualizar informações médicas nas diferentes modalidades de aquisição da imagem. Imagens clínicas não são contun-dentes, na verdade se caracterizam por uma composição de pequenas diferenças que podem ser traduzidas pela variação de fundo e efeitos específicos de aquisição. Portanto, percebe-se uma real necessidade de estudos específicos neste campo.

As principais fases de um sistema de visão computacional (VC) são: aquisição de imagens, realce, segmentação, extração de atributos ou características, classificação e reconhecimento e decisão [49], etapas que foram tratadas ao longo desta Tese.

3.2 Aquisição e digitalização da imagem

Radiografias simples de tórax de 49 pacientes foram adquiridas na posição pósterio-anterior com um aparelho Siemens (modelo LX30; Siemens AG, Erlangen,

Alemanha), tendo distância de 180cm entre foco e filme, regime de 80 kVp e tempo de exposição de 0,04 ms.

Os filmes radiográficos foram digitalizados pelo software scanRX [50], Figura 3.1, juntamente com um scanner de transparência simples modelo ScanMaker i800, marca Microtek de tamanho A4. O software scanRX combina partes digitalizadas da imagem em quatro etapas formando uma nova imagem completa com nenhum sinal de ruído entre as costuras e apresentando 95% de assertividade na tradução do filme radiográfico para o formato digital.

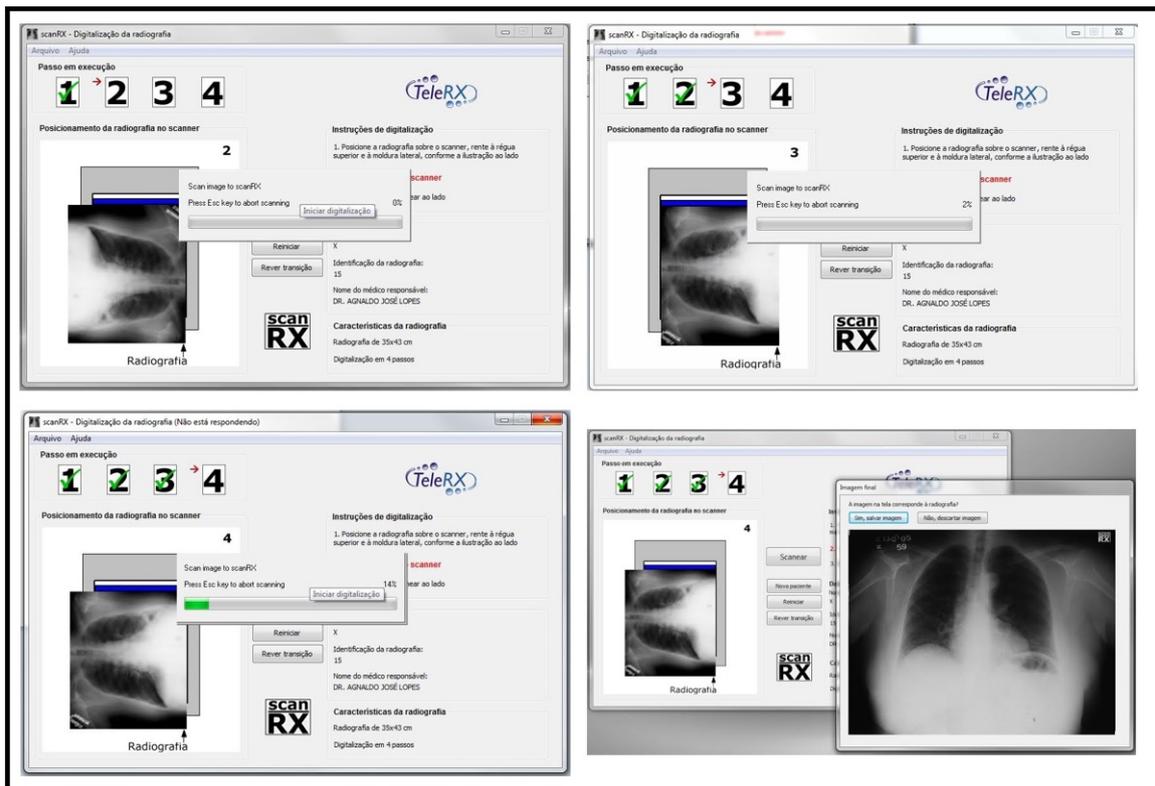


Figura 3.1: Passo à passo das etapas do scanRX.

Há dois conceitos importantes relacionados à imagem digital: amostragem da imagem e quantização de cada um dos seus pixels. Essas propriedades são relativas ao processamento computacional de uma imagem, sendo a primeira referente ao número de pontos por polegada [*dots per inch* (dpi)] amostrados de uma imagem digitalizada e a segunda, à quantidade de níveis de tons de que pode ser atribuído a cada ponto digitalizado [49].

Cabe-se ressaltar que na padronização da digitalização dessas imagens, considerou-se o tamanho do elemento de imagem (pixel) igual a 83,66 μ m (milésima parte do milímetro) – equivalente à resolução de 300dpi e quantização por pixel de 8 bits, equivalente a 256 níveis de cinza [0,255].

Finda a etapa de transformação dos 49 filmes radiográficos em imagens digitais,

onde foram descartados 9 (nove) filmes por ausência dos testes de função pulmonar (TFP), foi realizado o pré-processamento de cada imagem ajustando-as por algoritmo implementado no software Matlab® R2015a, discriminado na próxima seção.

3.3 Pré-processamento

A imagem digital de uma radiografia simples de tórax tem a peculiaridade de possuir características de deterioração, ruídos na profundidade de cor dos pixels. Sendo assim, cabe realizar o realce ou ajuste que tem por objetivo realçar detalhes da imagem que são de interesse do especialista, no caso específico do estudo realizado nesta Tese, na identificação da área pulmonar acometida pela fibrose no caso de pacientes com esclerose sistêmica (ES).

A filtragem da imagem depende de técnicas de transformações aplicadas pixel a pixel, levando em consideração os níveis de cinza de cada pixel e os de seus vizinhos. Um dos principais objetivos para filtragem no domínio da frequência é a nitidez através da ampliação do seu contraste e acentuação de especificidades [49].

Neste estudo específico, entendeu-se que havia necessidade de acentuar a tonalidade dos pixels e realçar o contraste de uma imagem em escala de cinza pelas seguintes proposições [51]:

- SE um pixel for preto, ENTÃO faça com que se torne mais preto;
- SE um pixel for cinza, ENTÃO faça com que se torne mais cinza; e,
- SE um pixel for branco, ENTÃO faça com que se torne mais branco.

Os termos "preto", "cinza" e "branco" considerados como variáveis linguísticas, com suas respectivas funções de pertinência, $\mu_{preto}(x)$, $\mu_{cinza}(x)$ e $\mu_{branco}(x)$, permitem obter uma média ponderada da profundidade de cor dos pixels da imagem, Figura 3.2, pela expressão:

$$v_0 = \frac{\mu_{preto}(Z_0) * v_p + \mu_{cinza}(Z_0) * v_c + \mu_{branco}(Z_0) * v_b}{\mu_{preto}(Z_0) + \mu_{cinza}(Z_0) + \mu_{branco}(Z_0)}$$

onde v_0 é a profundidade de cor do pixel em realce, v_p é o valor limite da pertinência máxima no preto, v_c é o valor correspondente a pertinência no cinza e v_b é o valor limite da pertinência máxima no branco. O uso desta função aplicada a cada pixel da imagem reduz significativamente os requisitos de processamento computacional [51].

A visualização do histograma de uma imagem em tons de cinza com 2^8 bits [0, 255], mostra que os pixels de cor preta deslocam-se para a esquerda (próximo de 0),

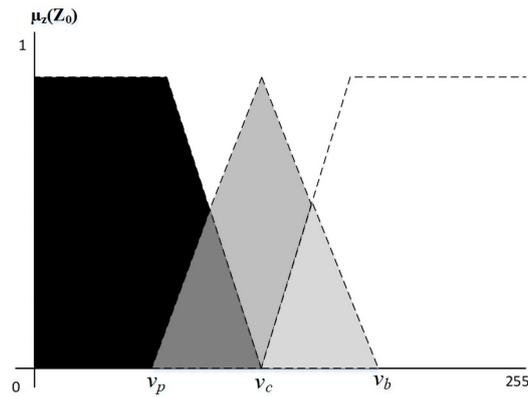


Figura 3.2: Conjunto *fuzzy* trapezoidal triangular.

modificando a profundidade da cor e os pixels de cor branca para a direita (próximo de 255), enquanto que os níveis médios de cinza são suavizados.

O esquema de pré-processamento objetivando o ajuste da imagem usando o método *fuzzy* pode ser visualizado na Figura 3.3.



Figura 3.3: Esquema da etapa de pré-processamento para ajuste da imagem.

Uma vez que as transformações de intensidade da profundidade de cor dos pixels foram realizadas e conseguiu-se um aprimoramento na visualização da imagem, passou-se para a fase de segmentação da imagem que foi tratada na seção à seguir.

3.4 Segmentação

Segmentação é uma dentre as principais etapas do processamento de imagem, na qual a mesma é dividida em várias partes. Cada segmento pode representar uma diversidade de informações como variedade de cor, intensidade ou textura. É um processo de identificação e delineamento de objetos. A segmentação se faz necessária uma vez que facilita o conhecimento do objeto que se deseja obter a partir de uma imagem [52].

O objetivo da segmentação é fazer com que os objetos e as áreas de interesse em uma imagem tenham os seus pixels agrupados e destacados dos demais [49], além de subdividir a imagem de entrada em regiões significativas, porém, a forma selecionada dependerá da característica da imagem e do problema a ser resolvido [53].

Sabe-se que não há uma metodologia ideal para segmentação de imagem, uma

vez que cada imagem tem sua própria peculiaridade, além de ser uma tarefa árdua procurar uma técnica de segmentação para um determinado grupo de imagens [54].

Cardenas *et al.* (2013) cita que as técnicas de segmentação podem ser divididas em 3 diferentes maneiras, sendo elas:

- Manual – onde um operador faz o delineamento manual das regiões de interesse;
- Semiautomático – onde um operador demarca um ponto ou um contorno aproximado na área de interesse e um algoritmo finaliza a segmentação; e,
- Automático – onde um software faz todo o trabalho de segmentação e o operador apenas indica as imagens a serem segmentadas.

A segmentação pode ser baseada nas discontinuidades ou nas similaridades dos diferentes aspectos da imagem e podem ser baseadas em limites (bordas) ou áreas (regiões).

A segmentação orientada ou baseada em regiões é a partição da imagem que considera grupos de pixels associando a padrões de tonalidade ou de forma objetivando-se a separação dessas regiões. Todavia, a associação delas é uma etapa seguinte que consiste na interpretação ou rotulação, embora as técnicas de inteligência artificial (IA), quando aplicadas, sejam capazes de associá-las. A agregação das regiões é feita enquanto um critério de similaridade ou de decisão for verdadeiro e o processo de crescimento de uma região deve ser limitado quando não houver mais pixels vizinhos que satisfaçam ao critério de inclusão na região. O crescimento de regiões emprega um conjunto de descritores baseados em intensidade e em propriedades espaciais de uma única fonte de imagens. Porém, a informação de conectividade ou de adjacência deve ser considerada no processo de crescimento de regiões, pois o emprego desses descritores isoladamente pode conduzir a resultados enganosos [49].

Segmentação de imagens é um dos passos mais importantes na análise de dados de imagem do paciente e pode ajudar no diagnóstico, categorização funcional e prognóstico, assim como na avaliação das intervenções terapêuticas.

Na segmentação de imagens, o primeiro passo corresponde à aquisição da imagem por meio de algum dispositivo computacional que a transforme em uma imagem digital, conjunto de pontos chamado pixels que discretizam os componentes da região de interesse. A imagem digital então é expressa por uma função $f(x, y)$ de duas coordenadas no plano bidimensional.

Um dos principais métodos para segmentação de imagens em escala de cinza é o método de Otsu [8]. Como alternativa a este método, apresentam-se os sistemas de lógica *fuzzy* (SLF) que não só são ótimos no que diz respeito ao tratamento de

incertezas, mas também adquirem o conhecimento de forma fácil e confiável, o que leva a utilização de SLF em imagens como uma forma bem natural [49].

A lógica *fuzzy* é uma poderosa ferramenta capaz de capturar informações imprecisas, descritas em linguagem natural, e convertê-las para um formato numérico e categórico. Tradicionalmente, uma posição lógica pode ter dois extremos: “verdadeiro” ou “falso”. Entretanto, na lógica *fuzzy*, uma premissa varia em grau de verdade ou pertinência de 0 a 1, o que leva a ser parcialmente verdadeira ou parcialmente falsa [55].

Apresentam-se nas próximas subseções o método clássico de segmentação de imagens em escala de cinza de Otsu [8] e o método de segmentação sob a ótica dos conjuntos intuicionistas *fuzzy* [31], proposto para esta Tese.

Uma vez realizada a segmentação, etapa fundamental no primeiro estágio do processo de reconhecimento, busca-se a identificação dos padrões presentes em uma imagem. Nesta fase, só é possível reconhecer um dado objeto se este estiver "separado" dos demais elementos contidos na imagem e, para realizar a classificação, torna-se necessário utilizar alguma técnica de decisão. Existem várias abordagens para isso, indo de critérios bem simples, como distância mínima e funções discriminantes, ao uso de técnicas de IA como: algoritmos genéticos, clusterização, lógica *fuzzy* ou redes neurais artificiais [49].

3.4.1 Segmentação pelo método de Otsu

Segundo Otsu (1979), um histograma pode ter uma depressão nítida entre dois conjuntos que vem a representar objeto e fundo, dicotomizado por um limiar k , Figura 3.4 .

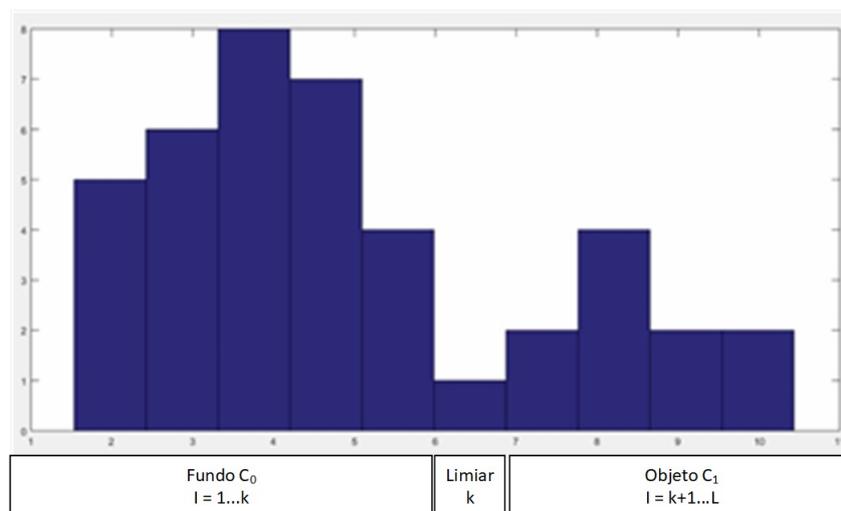


Figura 3.4: Exemplo de histograma de uma imagem.

Entretanto, na maioria das imagens é frequentemente difícil detectar a depressão

inferior com precisão, principalmente em casos quando o vale é plano e largo, imbuído de ruído ou quando os dois picos são extremamente desiguais na altura.

A descrição do método de limiarização de Otsu direciona-se a uma imagem que representa L níveis de cinza. O número de pixels no nível i é denotado por n_i e o total de pixels por N :

$$N = \sum_{i=1}^L n_i.$$

Dessa forma, as probabilidades de ocorrência em cada classe são:

$$\omega_0 = Pr(C_0) = \sum_{i=1}^k p_i = \omega(k)$$

$$\omega_1 = Pr(C_1) = \sum_{i=k+1}^L p_i = 1 - \omega(k)$$

onde a média dos pixels que representam o fundo é:

$$\mu_0 = \sum_{i=1}^k i Pr(i|C_0)$$

a média dos pixels que representam o objeto é:

$$\mu_1 = \sum_{i=k+1}^L i Pr(i|C_1)$$

e a média global da imagem original é:

$$\mu_T = \sum_{i=1}^L i P_i$$

As variâncias em cada conjunto são representadas por:

$$\sigma_0^2 = \sum_{i=1}^k (i - \mu_0)^2 Pr(i|C_0)$$

e

$$\sigma_1^2 = \sum_{i=k+1}^L (i - \mu_1)^2 Pr(i|C_1)$$

Para avaliar o ajuste do limiar (no nível k), introduziu-se as seguintes medidas de separabilidade de classes, utilizadas na análise discriminante [56]:

$$\lambda = \sigma_B^2 / \sigma_W^2$$

$$k = \sigma_T^2 / \sigma_W^2$$

$$\eta = \sigma_B^2 / \sigma_T^2$$

onde a variância dentro, assume a expressão:

$$\sigma_W^2 = \omega_0 \sigma_0^2 + \omega_1 \sigma_1^2$$

a variância entre, assume a expressão:

$$\sigma_B^2 = \omega_0 (\mu_0 - \mu_T)^2 + \omega_1 (\mu_1 - \mu_T)^2$$

e a variância total, assume a expressão:

$$\sigma_T^2 = \sum_{i=1}^L (i - \mu_T)^2 P_i = \sigma_W^2 + \sigma_B^2 = \sigma_T^2$$

A representação gráfica das premissas do método se apresenta na Figura 3.5.

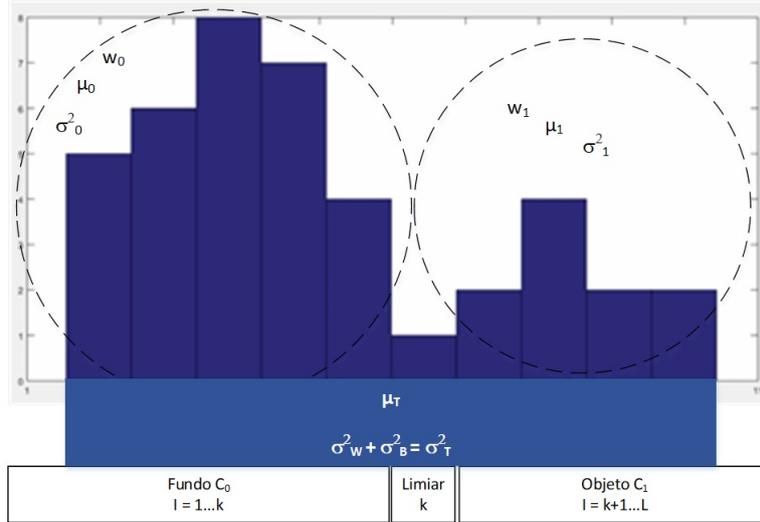


Figura 3.5: Representação gráfica das premissas do método de Otsu.

O problema reduz-se a otimização para alcançar o limiar k que separa as classes de níveis de cinza. O critério discriminante maximiza λ , k e η . De forma equivalente, tal que $k = \lambda + 1$ e $\eta = \lambda / (\lambda + 1)$, garante que:

$$\sigma_W^2 + \sigma_B^2 = \sigma_T^2.$$

A adoção de η como critério de mensurar a evolução da separabilidade do limiar no nível k , corresponde ao índice relativo da variância entre as classes de níveis de cinza em relação à variância total.

O limiar ótimo k^* que maximiza η ou σ_B^2 é selecionado em uma busca sequencial pelas probabilidades cumulativas e das respectivas médias ou usando:

$$\eta(k) = \sigma_B^2(k)/\sigma_T^2$$

$$\sigma_B^2(k) = \frac{[\mu_T\omega(k) - \mu(k)]^2}{\omega(k)[1 - \omega(k)]},$$

sendo assim, o limiar ótimo k^* , Figura 3.6, será:

$$\sigma_B^2(k^*) = \max_{1 \leq k < L} \sigma_B^2(k).$$

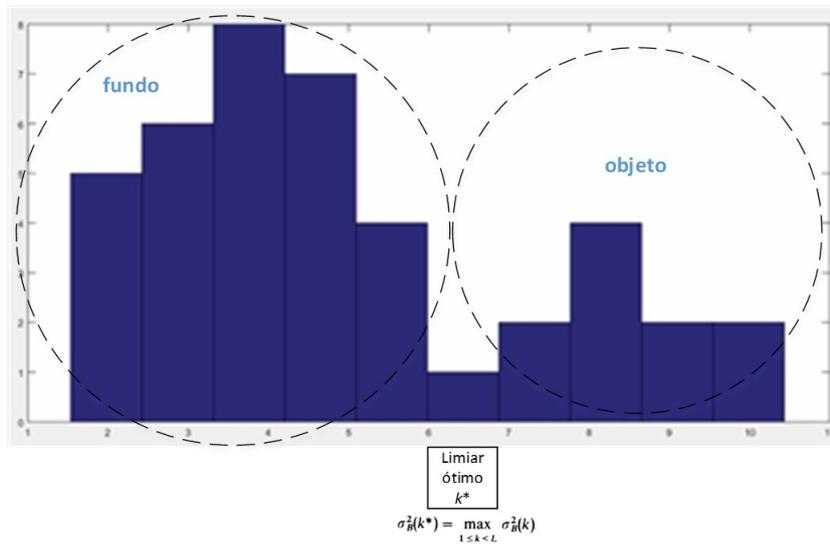


Figura 3.6: Representação gráfica do limiar ótimo pelo método de Otsu.

A partir deste problema, a variação de k maximizante do critério de separabilidade está restrito a:

$$S^* = \{k; \omega_0\omega_1 = \omega(k)[1 - \omega(k)] > 0, \text{ ou, } 0 < \omega(k) < 1\}.$$

Este método tem, entre outras vantagens, a de encontrar um limite ótimo não baseado na propriedade local, mas sim na propriedade global do histograma. Seleciona-se o limiar automaticamente a partir de um histograma de níveis de cinza derivado segundo a análise discriminante que conduz a uma melhor separabilidade de classes e pode ser recomendado como o padrão mais simples para a seleção automática de limiares [8].

O esquema para segmentação pelo método de Otsu pode ser visualizado na Figura 3.7.

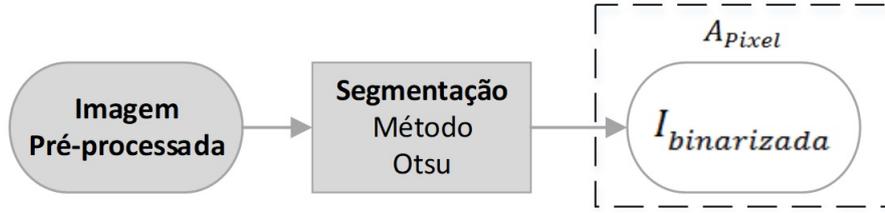


Figura 3.7: Esquema de segmentação pelo método de Otsu.

3.4.2 Segmentação pelos conjuntos intuicionistas *fuzzy*

Na segmentação segundo os conjuntos intuicionistas *fuzzy* (CIF) [31][57], considera-se uma imagem A de tamanho $M \times N$ pixels com L níveis de cinza ordenados entre 0 e $L-1$. De acordo com Pal e King [58][59][60], uma imagem pode ser considerada como uma matriz cujo elementos denotam os valores de pertinência dos níveis de cinza G_{ij} , correspondendo a um dos pares ordenados de um pixel. Os valores de pertinência foram obtidos segundo o princípio de extensão *fuzzy*, que corresponde a um dos conceitos mais básicos da teoria dos conjuntos *fuzzy* e que pode ser usado para generalizar conceitos matemáticos nítidos para conjuntos *fuzzy*[61]. Nesse caso, uma imagem pode ser representada como um conjunto *fuzzy*:

$$A = \{ \langle g_{ij}, \mu_A(g_{ij}) \rangle \mid g_{ij} \in \{0, \dots, L-1\} \},$$

onde $i \in 1, \dots, M$ e $j \in 1, \dots, N$. Para a tarefa de segmentação de imagem, considerou-se as médias ponderadas dos níveis de cinza das respectivas classes do histograma.

Motivados pelo trabalho de Chaira e Ray (2003)[62], Vlachos e Sergiadis (2007)[57] estenderam a proposta para os conjuntos intuicionistas *fuzzy*.

Um conjunto *fuzzy* intuicionista A definido sob um universo X segundo Atanassov (1999)[63], assume a expressão:

$$A = \{ \langle x, \mu_A(x), \nu_A(x) \rangle \mid x \in X \}$$

onde $\mu_A(x)$ e $\nu_A(x)$ pertencem ao intervalo $[0, 1]$ com a condição:

$$0 \leq \mu_A(x) + \nu_A(x) \leq 1,$$

para todo $x \in X$.

Os valores $\mu_A(x)$ e $\nu_A(x)$ correspondem ao grau de pertinência e não pertinência de x em A , respectivamente.

Para um conjunto intuicionista *fuzzy* A , chama-se índice intuicionista de um elemento $x \in X$ em A , a expressão:

$$\pi_A(x) = 1 - \mu_A(x) - v_A(x),$$

sendo que o π_A pode ser considerado como o grau de hesitação de x em A . Naturalmente é evidente que:

$$0 \leq \pi_A(x) \leq 1,$$

para todo $x \in X$.

Dado um determinado limiar T que separa o objeto do fundo, o nível médio de cinza do fundo é dado por:

$$m_F = \frac{\sum_{g=0}^T gh_A(g)}{\sum_{g=0}^T h_A(g)},$$

enquanto o do objeto é dado por:

$$m_O = \frac{\sum_{g=T+1}^{L-1} gh_A(g)}{\sum_{g=T+1}^{L-1} h_A(g)},$$

onde h_A é a frequência do histograma da imagem A . A função de pertinência para os conjuntos *fuzzy* de cada pixel na imagem segundo Chaira e Ray (2003)[62] é determinada usando a distribuição gama, pelas expressões:

$$\mu_A(g; T) = \begin{cases} \exp\left(-\frac{1}{g_{max}-g_{min}}|g - m_F|\right) & , Se g \leq T \\ \exp\left(-\frac{1}{g_{max}-g_{min}}|g - m_O|\right) & , Se g > T \end{cases}$$

onde g_{min} e g_{max} são os níveis de cinza da imagem mínimo e máximo respectivamente.

Baseado nas pertinências dos conjuntos *fuzzy* descritos anteriormente, construiu-se as funções de pertinência e de não pertinência do CIF, que segue:

$$\mu_A(g; T) = \lambda \mu_A(g; T)$$

e

$$v_A(g; T) = (1 - \mu_A(g; T))^\lambda$$

onde $\lambda \in [0, 1]$. Simulações mostraram que o parâmetro de ajuste $\lambda = 0,2$ produz o melhor resultado global em relação à minimização das medidas de discrepância empírica[57]. A imagem no domínio intuicionista *fuzzy* é representada pelo CIF:

$$A = \{\langle g, \mu_A(g), v_A(g) \rangle \mid g \in \{0, \dots, L - 1\}\}.$$

Verifica-se que A de fato é um CIF, desde que $0 \leq \mu_A(g; T) + v_A(g; T) \leq 1$ para qualquer $\lambda \in [0, 1]$ e para todo $g \in [0, \dots, L - 1]$.

Seja T_{otimo} um limiar ótimo de uma imagem segmentada na qual o objeto e o fundo estão precisamente discriminados. A ideia subjacente à abordagem de Chaira e Ray (2003) [62] é a minimização da divergência *fuzzy* entre o limiar ideal da imagem (T_{otimo}) e o observado inicialmente (T) que induz ao pertencimento máximo de cada pixel à sua região, seja objeto ou fundo. Consequentemente, após a limiarização, espera-se que a imagem limiarizada aproximar-se-á da imagem idealmente segmentada.

A medida discriminante para o CIF foi obtida segundo a expressão:

$$D_{CIF}(A; T_{otimo}; T) = \sum_{g=0}^{L-1} h_A(g) \left(\mu_A(g; T) \ln \frac{2\mu_A(g; T)}{1 + \mu_A(g; T)} + v_A(g; T) \ln 2 + \ln \frac{2}{1 + \mu_A(g; T)} \right).$$

Dessa forma, o limiar T_{otimo} corresponde a expressão:

$$T_{otimo} = \operatorname{argmin}_T \{D_{CIF}(A, T_{otimo}; T)\}$$

onde $T \in [gmin, \dots, gmax]$ e T_{otimo} é o limiar ideal para a segmentação. Nesse sentido, ao obter-se o limiar ideal, binariza-se a imagem.

Há necessidade ainda de se avaliar a entropia dos conjuntos intuicionistas *fuzzy*[57] de acordo com as seguintes propriedades:

- $E(A) = 0$ se somente se A for um conjunto *fuzzy*;
- $E(A) = \text{Cardinalidade}(x) = n$ se somente se $\mu_A(x) = v_A(x) = 0$ para todo $x \in X$;
- $E(A) \geq E(B)$ se $A \leq B$, isto é, $\mu_A(x) \leq \mu_B(x)$ e $v_A(x) \leq v_B(x)$ para todo $x \in X$; e,
- $E(A) = E(A^c)$;

Sabe-se que a entropia dos conjuntos *fuzzy* é uma medida de nebulosidade. Uma vez que os conjuntos intuicionistas *fuzzy* são uma generalização dos conjuntos *fuzzy*, então é esperado que haja uma conexão direta entre os conceitos de entropia e nebulosidade entre os dois conjuntos. Usando a generalização proposta por De Luca e Termini (1972) - LT[64], Vlachos e Sergiadis (2007)[57], propõe:

$$E_{LT}^{CIF}(A) = E_{fuzzy}(A) + E_{intuicionista}(A),$$

onde a $E_{fuzzy}(A)$ corresponde a:

$$E_{fuzzy}(A) = -\frac{1}{n \ln 2} \sum_{i=1}^n [\mu_A(x_i) \ln \mu_A(x_i) + v_A(x_i) \ln v_A(x_i) - (1 - \pi_A(x_i)) \ln(1 - \pi_A(x_i))]$$

e a $E_{intuicionista}(A)$ assume a expressão:

$$E_{intuicionista}(A) = \frac{\sum_{i=1}^n \pi_A(x_i)}{n}.$$

À primeira vista podemos observar que o termo $E_{fuzzy}(A)$ descreve a nebulosidade intrínseca do conjunto A , isto é, mede o quão difuso é o conjunto intuicionista *fuzzy* A , sendo que em relação a seus elementos predomina a condição de igualdade da pertinência e não pertinência delimitada por 0,5, isto é, $\mu_A(x) = v_A(x) = \frac{1}{2}$. A $E_{intuicionista}(A)$ consiste de dois componentes distintos, um matemático e outro intuitivo, que expressam o grau de nebulosidade e de intuição, respectivamente.

O esquema para segmentação pelo método sob a ótica dos CIF pode ser visualizado na Figura 3.9.

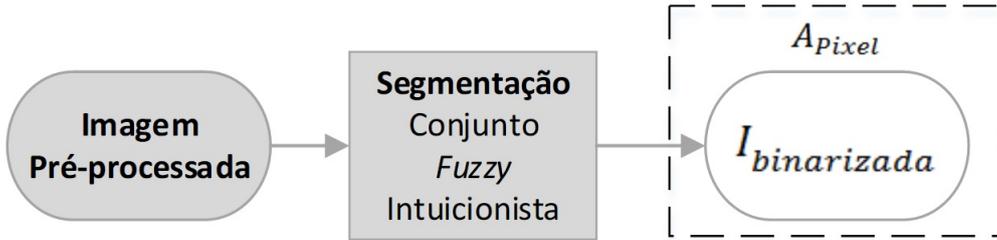


Figura 3.8: Esquema de segmentação sob a ótica dos conjuntos intuicionistas *fuzzy*.

3.5 Classificação do acometimento da fibrose pulmonar sob a ótica dos conjuntos *fuzzy*

O índice de intensidade da fibrose pulmonar (IIFP), criado a partir desta Tese, pôde ser obtido pela frequência dos pixels brancos contidos no intervalo $[Início_{pixelbranco}, 255]$ em relação à frequência de pixels da imagem após a etapa de binarização e segmentação pelo especialista. Este procedimento estabeleceu os pontos de corte para determinação dos conjuntos *fuzzy*[24] e seu respectivo suporte para o IIFP.

Dado um universo X e um elemento particular $x \in X$, o grau de pertinência $\mu_A(x)$ em relação a um conjunto $A \subseteq X$ é dado por:

$$\mu_A(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases}.$$

A função de pertinência $\mu_A(x) : X \rightarrow [0, 1]$ corresponde a uma função característica em que Zadeh [24][65][55][66] propôs uma caracterização mais ampla, na medida em que sugere que alguns elementos sejam mais pertinentes a algum determinado conjunto do que outros. Esta função pode então assumir qualquer valor entre 0 e 1, sendo que o valor 0 indica uma completa exclusão e um valor 1 completa pertinência. O conjunto *fuzzy* A em X é um conjunto de pares ordenados $A = \{\mu_A(x)/x, x \in X\}$, tal que o suporte deste conjunto é um subconjunto dos pontos x de X tal que $\mu_A(x) > 0$.

Um conjunto *fuzzy* cujo conjunto suporte tem um único elemento de X com $\mu_A(x) = 1$ é chamado de conjunto *fuzzy* unitário. Esta generalização aumenta o poder de expressão como uma função característica.

Por exemplo, em uma imagem digital em escala de cinza de 8 bits, tem-se 2^8 (256) possibilidades de profundidade de cor. Assim, o suporte de um conjunto *fuzzy* triangular varia de 0 a 255. Se x assumir um valor entre a e b , ou entre b e c , sendo b o valor correspondente ao valor mediano, a função de pertinência deverá seguir a expressão:

$$\mu_A(x) = \begin{cases} \frac{x-a}{b-a} & \text{se } x \in [a, b) \\ \frac{c-x}{c-b} & \text{se } x \in [b, c) \\ 0 & \text{caso contrario} \end{cases}$$

Graficamente, o conjunto *fuzzy* triangular assume a configuração expressa na Figura 3.9.

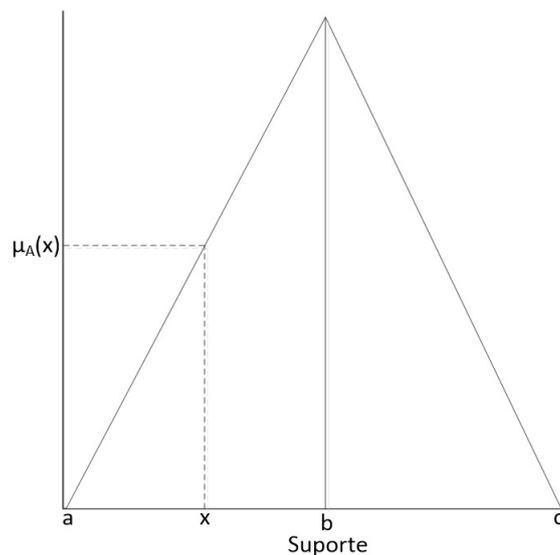


Figura 3.9: Conjunto *fuzzy* triangular.

De forma análoga, os valores de pertinências podem ser obtidos segundo o princípio de extensão [61] com o uso de uma função gaussiana. Nesta mesma linha,

pode-se utilizar um histograma normalizado pela caracterização de conjuntos *fuzzy* modais, isto é, $\mu_A(x) = 1$.

Uma variável linguística é aquela cujos valores são nomes de conjuntos *fuzzy*. Por exemplo, a profundidade da cor de um determinado pixel em uma imagem digital de 2^8 bits poderia ser uma variável linguística assumindo valores *preto*, *cinza* e *branco*, considerados conjuntos *fuzzy*, mas existem áreas de interseção entre os conjuntos que poderiam ser considerados como gradientes de *cinza*, Figura 3.10. Nesta interseção de dois conjuntos, deve-se assumir o valor da pertinência mínima no ponto x classificando-se como *cinza* com pertinência $\mu_{cinza}(x)$ [67].

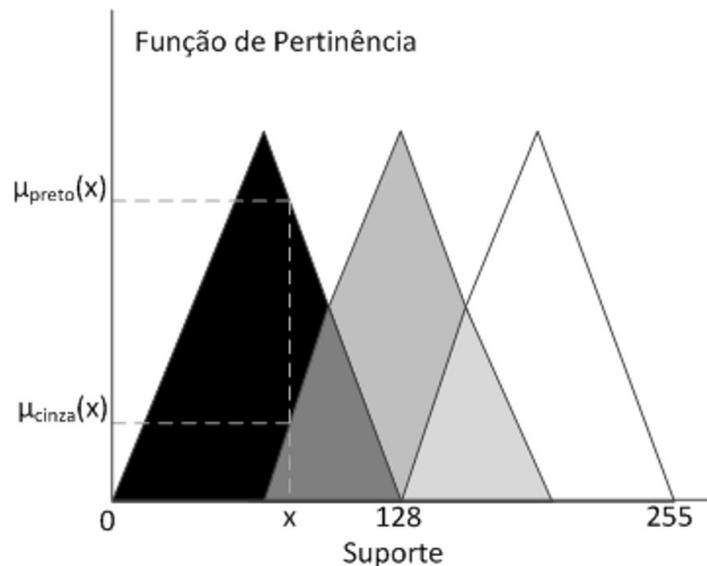


Figura 3.10: Conjunto *fuzzy* de uma imagem digital de 2^8 bits.

Alguns trabalhos desenvolvidos na linha de Gomide *et al.* (1995)[68], utilizam modificadores, que nesta Tese poderiam expressar a gradação "muito", "bastante" e "extremamente", por exemplo. Para gerar estes valores compostos, utilizam-se diversos termos, que podem ser divididos nas seguintes categorias:

- Termos Primários: nomes de conjuntos *fuzzy* especificados em um determinado universo, por exemplo, preto, cinza e branco;
- Conectivos Lógicos: a negação NÃO, conectivos E e OU;
- Modificadores: palavras como "muito", "pouco", "levemente" e "extremamente"; e,
- Delimitadores: como parênteses, por exemplo, (c,d).

Em essência, a utilização do tipo de descrição linguística permite o tratamento de sistemas de visualização que podem ser considerados muito complexos como, por exemplo, formas de aquisição/formação de uma imagem binária.

Para modelar um sistema *fuzzy* é necessário descrever o comportamento do mesmo em relação à análise e simulação com o uso das regras antecedente/consequente, que sob a visão *fuzzy* consiste em descrever a relação entre x e $f(x)$ através de regras do tipo:

$$\text{Regra } i : \text{ Se } x \text{ e } A_i \text{ entao } f(x) \text{ e } B_i, \quad i = 1, \dots, N,$$

onde x representa a variável independente e $f(x)$ a variável dependente, sendo A_i e B_i constantes linguísticas e N o número de observações que descreve a função. Esta relação *fuzzy* fornece valores compatíveis para qualquer dado no universo de interesse através do mecanismo de inferência *fuzzy*.

Bourгани *et al.* (2014) utilizaram os mapas cognitivos fuzzy para desenvolver diagnóstico médico em relação ao campo pulmonar considerando a evolução temporal da doença, uma vez que o diagnóstico pode ser modificado ao longo do tempo [69].

Warszawski *et al.* (2014) entendem a lógica *fuzzy* como uma metodologia integralmente viável no auxílio da definição do espaço de tolerância e benefícios em mutações de sistemas biomoleculares naturais e na construção de moléculas artificiais que codificam características complexas [70].

Kumar e Mohan (2014) propõem uma técnica baseada na lógica *fuzzy* para detecção das bordas em imagens do cérebro de ressonância magnética (RM) e foi possível detectar a aresta sem determinar os valores de limiar. Os resultados da proposta foram comparados com operadores clássicos de detecção de bordas como Sobel, Prewitt, Roberts e Canny [71].

Farahani *et al.* (2015) propôs como saída de um sistema lógico *fuzzy* uma segunda opinião de diagnóstico que poderia ser uma contribuição para os especialistas. Este sistema foi gerado segundo regras *fuzzy* "Se-Então" relacionadas ao diagnóstico de câncer de pulmão através de uma máquina de inferência *fuzzy* [72].

Ghosh *et al.* (2015) trataram características físicas do corpo humano capazes de expressar emoções pela abertura dos olhos, abertura bucal, comprimento da constrição da testa, entre outros, entendendo como sendo características *fuzzy* que variam de pessoa para pessoa usando a inferência *fuzzy* como meta na avaliação de emoções expressas por diferentes sujeitos [73].

Sridhar *et al.* (2015) propõem um método para detecção de câncer em imagens de mamografia com base na morfologia matemática adaptativa e sob a ótica dos sistemas *fuzzy*. A lógica *fuzzy* mostrou-se eficiente ao processar e gerar imagens com características específicas para a doença. Os resultados experimentais mostraram as características avançadas das imagens de câncer [74].

Javed *et al.* (2016) propuseram um modelo de contorno ativo de bordas ponderado baseado na lógica *fuzzy* para segmentação de imagens de radar. Além disso,

utilizaram mecanismo de inferência *fuzzy* para atribuir pesos a pixels da função de ajuste de nível com base na entropia e variação local. Resultados experimentais mostraram que a proposta melhorou a eficiência e a precisão da segmentação em comparação com o esquema de ajuste escalonável existente [75].

Barkana *et al.* (2017) utilizaram a lógica *fuzzy* na segmentação de vasos retinianos com o uso do princípio de extensão consubstanciado em medidas estatísticas descritivas, objetivando o diagnóstico precoce da retinopatia diabética, doença ocular diabética mais comum e uma das principais causas de cegueira no mundo [76].

Rubio *et al.* (2017) descreveram a implementação de um método para a detecção de microcalcificações em mamografias. No método proposto, as imagens são pré-processadas usando operadores de gradiente onde a saída de cada filtro é a entrada de um sistema *fuzzy* que detectou áreas com alta variabilidade de profundidade de cor [77].

Kaur *et al.* (2017) otimizaram a segmentação ao aplicar a lógica *fuzzy* na análise de texturas em imagens ressonância magnética (IRM) [78].

Nesta Tese, utilizou-se o *IIFP* como suporte para os conjuntos *fuzzy* para classificação do acometimento da fibrose pulmonar pela esclerose sistêmica (ES), Figura 3.11. De forma análoga, os conjuntos *fuzzy* foram aplicados na classificação das variáveis: capacidade vital forçada (*CVF*) e capacidade de difusão do monóxido de carbono (*D_{LCO}*), advindas dos exames de função pulmonar, Figura 3.12.

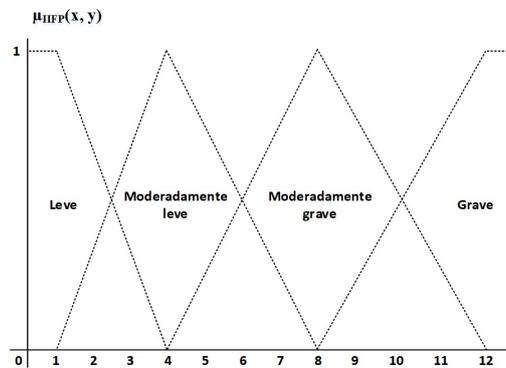


Figura 3.11: Conjunto *fuzzy* do *IIFP*.

Medidas de nebulosidade em contraste com pertinências *fuzzy*, tentam indicar o grau de nebulosidade de um conjunto *fuzzy* [61]. Nesta Tese, utilizou-se duas medidas de nebulosidade para os conjuntos *fuzzy* de suporte finito.

A primeira medida de nebulosidade, reporta-se a De Luca e Termini (1972)[64]. Seja $\mu_A(x)$ uma função de pertinência para o conjunto A para todo $x \in X$, sendo o X finito. A medida de nebulosidade $d(A)$ deve ter as seguintes propriedades:

- $d(A) = 0$ se e somente se A for um conjunto nítido de X ;

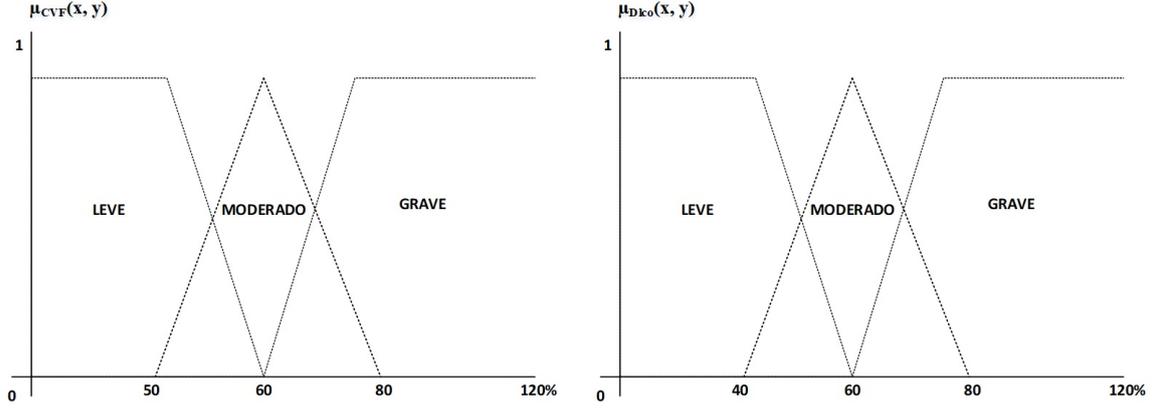


Figura 3.12: Conjuntos *fuzzy* da *CVF* e *D_{LCO}*.

- $d(A)$ assume um valor máximo unívoco se $\mu_A(x) = \frac{1}{2} \forall x \in X$;
- $d(A) \geq d(A')$ se A' é mais nítido do que o A ; e,
- $d(A^c) = d(A)$ onde A^c é um complemento de A .

Sob esta ótica a entropia de um conjunto *fuzzy* é definido como:

$$d(A) = H(A) + H(A^c), x \in X$$

$$H(A) = -K \sum_{i=1}^n \mu_A(x_i) \ln(\mu_A(x_i)),$$

onde n é o número de elementos no suporte de A e K é uma constante positiva, neste estudo $K = 1$.

Usando a função de Shannon $S(\mu_A(x)) = -\mu_A(x) \ln(\mu_A(x)) - (1 - \mu_A(x)) \ln(1 - \mu_A(x))$, os autores simplificaram a expressão da nebulosidade para a seguinte definição:

$$d(A) = K \sum_{i=1}^n S(\mu_A(x_i)).$$

Yager (1979) [79] sugeriu como alternativa à medida de nebulosidade, a métrica da distância entre o conjunto *fuzzy* e seu complemento, pela expressão:

$$f_p(A) = 1 - \frac{D_p(A, A^c)}{\|supp(A)\|},$$

sendo $f_p(A) \in [0, 1]$. Para $p = 1$, $D_1(A, A^c)$ conduz a expressão da métrica de Hamming:

$$D_1(A, A^c) = \sum_{i=1}^n |\mu_A(x_i) - \mu_{A^c}(x_i)|.$$

Uma vez que o conjunto *fuzzy* complementar $\mu_{A^c} = 1 - \mu_A$, a expressão torna-se:

$$D_1(A, A^c) = \sum_{i=1}^n |2\mu_A(x_i) - 1|$$

e para $p = 2$, $D_2(A, A^c)$ conduz similarmente a expressão da métrica Euclidiana:

$$D_2(A, A^c) = \left(\sum_{i=1}^n (2\mu_A(x_i) - 1)^2 \right)^{\frac{1}{2}}.$$

Finda a etapa de fuzzificação que permite categorizar quali-quantitativamente as variáveis CVF e D_{LCO} em $LEVE$, $MODERADO$ e $GRAVE$ e a variável $IIFP$ em $LEVE$, $MODERADAMENTE LEVE$, $MODERADAMENTE GRAVE$ e $GRAVE$, com as respectivas pertinências, optou-se em dar continuidade a análise com o uso do operador de média ponderada e hierarquizada, *ordered weight averaging* (OWA) [80], que permite obter uma média aritmética considerando ponderadores inerentes a cada categorização.

Sob esta ótica, A é definido como um mapeamento F de $I^n \rightarrow I$, onde $I = [0, 1]$, chamado operador OWA de dimensão N e se associado a F é um vetor de pesos W :

$$W = \begin{bmatrix} W_1 \\ W_2 \\ W_3 \end{bmatrix}$$

de tal modo que:

$$\begin{aligned} W_i &\in [0, 1] \\ \sum_i W_i &= 1 \end{aligned}$$

e onde:

$$f(a_1, a_2, \dots, a_n) = W_1 b_1 + W_2 b_2 + \dots + W_n b_n$$

onde b_i é o iésimo maior elemento do vetor a_1, a_2, \dots, a_n , sendo o vetor B de argumentos ordenados de tamanho n , tal que $b_i \in [0, 1]$ e $b_i \geq b_j$ se $j > i$. Dado um operador OWA F com vetor de pesos W e uma tupla de argumentos (a_1, a_2, \dots, a_n) , pode-se associar a esta tupla um vetor de entrada ordenada B tal que B é um vetor de argumentos de F discriminado em ordem decrescente. Assim:

$$F(a_1, \dots, a_n) = W' B$$

É importante enfatizar o fato de que os pesos W_i , estão associados a uma de-

terminada posição ordenada e não a um elemento particular, ou seja, W_i é o peso associado ao maior elemento, seja qual for o seu componente. Às vezes por conveniência, denota-se $F(a_1, \dots, a_n)$ como $F(B)$ onde B é um vetor de argumento associado ordenado. Nota-se que pode ser facilmente mostrado que para qualquer vetor de argumento ordenado B e qualquer operador OWA F com vetor de ponderação W , ocorre:

$$0 \leq F(B) \leq 1.$$

O ponderador W_i inerente a OWA, reflete a similitude da hierarquia inerente às variáveis linguísticas, *LEVE*, *MODERADO* e *GRAVE* para as variáveis *CVF* e *D_{LCO}* e *LEVE*, *MODERADAMENTE LEVE*, *MODERADAMENTE GRAVE* e *GRAVE* para a variável *IIFP*, respectivamente. A contribuição nesta fase, corresponde ao cálculo do momento ponderado centrado de 2ª ordem, variância que permite avaliar a variabilidade relativa pelo coeficiente de variação [81].

Objetiva-se saber qual das variáveis advindas do exame de função pulmonar, *CVF* e *D_{LCO}*, tem maior afinidade com o *IIFP*, obtido pelo processamento e segmentação da radiografia simples de tórax digitalizada. Esta meta foi alcançada segundo a análise da concordância atribuída a Bland Altman [37], em relação às pertinências obtidas pelos conjuntos *fuzzy* trapezoidais e triangulares para *IIFP* e para o *CVF* e *D_{LCO}*.

Bland e Altman avaliam a concordância entre a diferença dos valores para duas variáveis e a média entre elas por meio do gráfico de dispersão que permite visualizar o viés (o quanto as diferenças se afastam do valor nulo), o erro (dispersão dos pontos das diferenças ao redor da média) além dos *outliers* e tendências.

No presente estudo, entende-se viés como a diferença das pertinências ponderadas oriundas da categorização para o *IIFP* x *CVF* e *IIFP* x *D_{LCO}*. A partir dos vieses chega-se aos limites de concordância para os pareamentos *IIFP* x *CVF* e *IIFP* x *D_{LCO}*, obtidos pela média dos desvios (\bar{D}) \pm e o erro padrão da média dos desvios ($EP_{\bar{D}}$), com a adoção do valor padronizado da distribuição de probabilidade *t* de *student* correspondente ao percentil 97,5 (*t*). O intervalo de concordância assume a expressão:

$$\bar{D} \pm t \times EP_{\bar{D}}$$

ou

$$\bar{D} \pm t \times \frac{S_D}{\sqrt{n-1}},$$

onde n corresponde ao tamanho da amostra e S_D o desvio padrão amostral dos

vieses [82]. Esse método continua sendo usado com frequência na literatura médica [83] [84][85].

Aferida a concordância entre o *IIFP* e as variáveis *CVF* e *D_{LCO}*, deu-se prosseguimento ao sistema inferencial *fuzzy* "Se... Então" que propicia um reconhecimento de padrão para o acometimento da fibrose pulmonar pela esclerose sistêmica (ES) por meio de duas máquinas inferenciais, *IIFP* x *CVF* e *IIFP* x *D_{LCO}*, que classificam e expressam a intensidade da doença. A Tabela 3.1 representa a máquina inferencial *fuzzy* do *IIFP* x *CVF*.

Tabela 3.1: Máquina inferencial *fuzzy* do *IIFP* x *CVF*.

		<i>CVF</i>		
		Leve	Moderado	Grave
<i>IIFP</i>	Leve	Leve	Moderadamente Leve	Moderado
	Moderado	Moderadamente Leve	Moderado	Moderadamente Grave
	Grave	Moderado	Moderadamente Grave	Grave

A máquina de inferência *fuzzy* do *IIFP* x *CVF*, apresenta 9 (nove) regras:

- 1^a regra: Se o *IIFP* for *LEVE* e o *CVF* for *LEVE*, a classificação final será *LEVE*.
- 2^a regra: Se o *IIFP* for *LEVE* e o *CVF* for *MODERADO*, a classificação final será *MODERADAMENTE LEVE*.
- 3^a regra: Se o *IIFP* for *LEVE* e o *CVF* for *GRAVE*, a classificação final será *MODERADO*.
- 4^a regra: Se o *IIFP* for *MODERADO* e o *CVF* for *LEVE*, a classificação final será *MODERADAMENTE LEVE*.
- 5^a regra: Se o *IIFP* for *MODERADO* e o *CVF* for *MODERADO*, a classificação final será *MODERADO*.
- 6^a regra: Se o *IIFP* for *MODERADO* e o *CVF* for *GRAVE*, a classificação final será *MODERADAMENTE GRAVE*.
- 7^a regra: Se o *IIFP* for *GRAVE* e o *CVF* for *LEVE*, a classificação final será *MODERADO*.
- 8^a regra: Se o *IIFP* for *GRAVE* e o *CVF* for *MODERADO*, a classificação final será *MODERADAMENTE GRAVE*.
- 9^a regra: Se o *IIFP* for *GRAVE* e o *CVF* for *GRAVE*, a classificação final será *GRAVE*.

Em relação às pertinências, há áreas de interseção entre dois conjuntos *fuzzy*, que segundo Mandani [67], assume-se o valor de pertinência mínima, determinando o valor de pertinência da variável linguística classificatória para as variáveis *IIFP* e *CVF*. A interação entre o *IIFP* e a *CVF*, infere à classificação quali-quantitativa do nível de acometimento de fibrose pulmonar pela esclerose sistêmica (ES), expressando a variável linguística decisória com a respectiva pertinência inferida por:

$$\mu_{decisao}(x) = \max \{ \mu_{IIFP}(x), \mu_{CVF}(x) \} \text{ para } x \in X.$$

Analogamente, para a interação entre o *IIFP* e o *D_{LCO}*, adotou-se o mesmo procedimento, gerando a máquina de inferência *fuzzy* expressa na Tabela 3.2.

Tabela 3.2: Máquina inferencial *fuzzy* do *IIFP* x *D_{LCO}*.

		<i>D_{LCO}</i>		
		Leve	Moderado	Grave
<i>IIFP</i>	Leve	Leve	Moderadamente Leve	Moderado
	Moderado	Moderadamente Leve	Moderado	Moderadamente Grave
	Grave	Moderado	Moderadamente Grave	Grave

A regras *fuzzy* são discriminadas:

- 1^a regra: Se o *IIFP* for *LEVE* e o *D_{LCO}* for *LEVE*, a classificação final será *LEVE*.
- 2^a regra: Se o *IIFP* for *LEVE* e o *D_{LCO}* for *MODERADO*, a classificação final será *MODERADAMENTE LEVE*.
- 3^a regra: Se o *IIFP* for *LEVE* e o *D_{LCO}* for *GRAVE*, a classificação final será *MODERADO*.
- 4^a regra: Se o *IIFP* for *MODERADO* e o *D_{LCO}* for *LEVE*, a classificação final será *MODERADAMENTE LEVE*.
- 5^a regra: Se o *IIFP* for *MODERADO* e o *D_{LCO}* for *MODERADO*, a classificação final será *MODERADO*.
- 6^a regra: Se o *IIFP* for *MODERADO* e o *D_{LCO}* for *GRAVE*, a classificação final será *MODERADAMENTE GRAVE*.
- 7^a regra: Se o *IIFP* for *GRAVE* e o *D_{LCO}* for *LEVE*, a classificação final será *MODERADO*.
- 8^a regra: Se o *IIFP* for *GRAVE* e o *D_{LCO}* for *MODERADO*, a classificação final será *MODERADAMENTE GRAVE*.

Capítulo 4

Resultados

Para esta etapa, foram utilizadas 49 imagens radiográficas simples de tórax digitas adquiridas conforme descrito na sessão 4.2. Entretanto, 9 imagens foram descartadas, pois não apresentavam os resultados dos exames de função pulmonar, apenas o radiográfico. As imagens utilizadas foram de 40 humanos de ambos sexos, todos diagnosticados com esclerose sistêmica (ES) e com algum acometimento pulmonar. Todas imagens foram adquiridas do Centro de Pneumologia do Hospital Universitário Pedro Ernesto (HUPE) da Universidade do Estado do Rio de Janeiro (UERJ). O protocolo de estudo foi aprovado pelo comitê de ética e os pacientes assinaram o formulário de consentimento livre e esclarecido.

Todos os algoritmos descritos nesta Tese foram desenvolvidos no Matlab®R2015a, sendo esta escolha, devido ao fato do *framework* ser uma poderosa ferramenta para execução de comandos e que contém diversas funções matemáticas e de processamento de imagens já implementadas. Além disso, disponibiliza recursos que nos permite codificar facilmente algoritmos. Sendo assim, desenvolveu-se o SisRPIP – Sistema de Reconhecimento de Padrão em Imagens Pulmonares, que nos permitiu implementar, manipular e testar tanto o método rígido de Otsu quanto o método alternativo *fuzzy* descritos nesta Tese. O SisRPIP também permite a entrada dos dados oriundos dos exames de função pulmonar e é capaz de classificá-los segundo os conjuntos *fuzzy*. Este sistema é capaz de criar o índice de intensidade de fibrose pulmonar (*IIFP*) a partir da segmentação da imagem, classifica-lo segundo os conjuntos *fuzzy* e associa-lo às classificações pelo método *fuzzy* das variáveis advindas do exame de função pulmonar para reconhecer o padrão do nível de acometimento pulmonar pela esclerose sistêmica. Podemos visualizar na Figura 4.1 a tela inicial do SisRPIP.

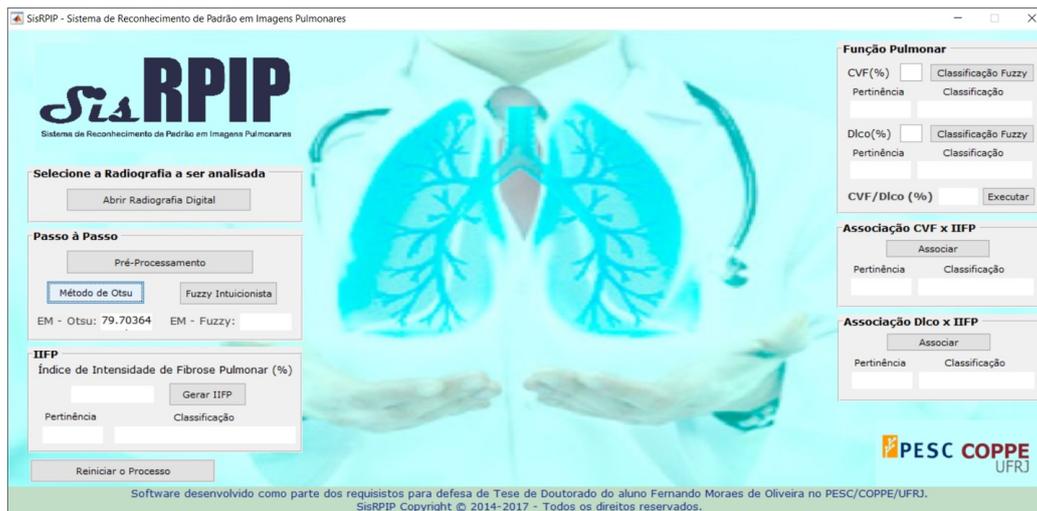


Figura 4.1: Tela inicial do SisRPIP.

4.1 Segmentação por Otsu

A primeira etapa do SisRPIP, ora exemplificada nesta seção, contemplou a seleção da radiografia simples de tórax digital, Figura 4.2.

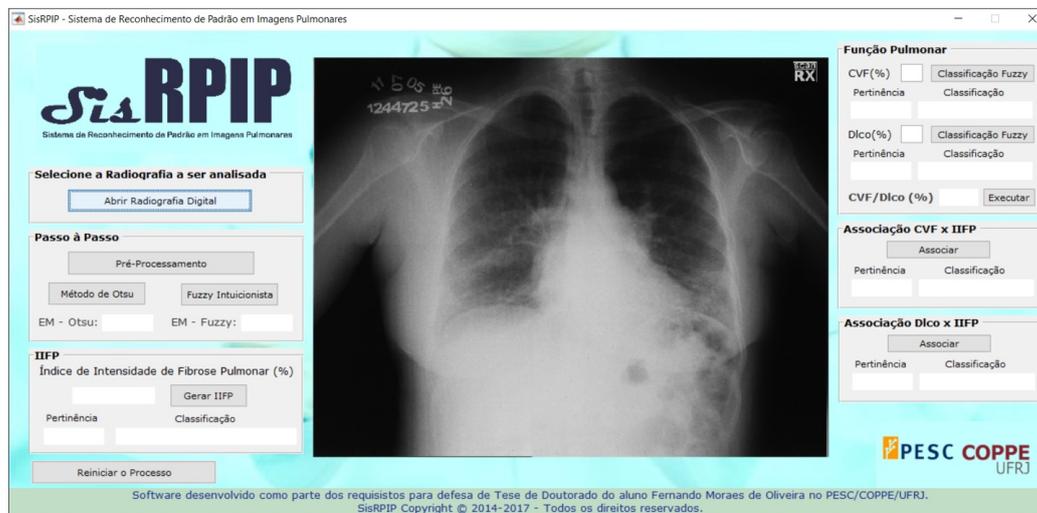


Figura 4.2: Tela inicial do SisRPIP quando selecionada a imagem.

A próxima etapa consiste em realizar o pré-processamento com o objetivo de ajustar o contraste para melhor definição das cores dos pixels em escala de cinza. Realçar a imagem na transformação quanto à intensidade da profundidade da cor dos pixels têm por objetivo destacar detalhes que são peculiares a análise do especialista. Após a seleção do botão “Pré-Processamento” no SisRPIP, a imagem é ajustada e dois histogramas são gerados, Figura 4.3.

O primeiro reflete a imagem original e o segundo a imagem pré-processada que estende o suporte do eixo da abscissa aos limites esperados para profundidade de

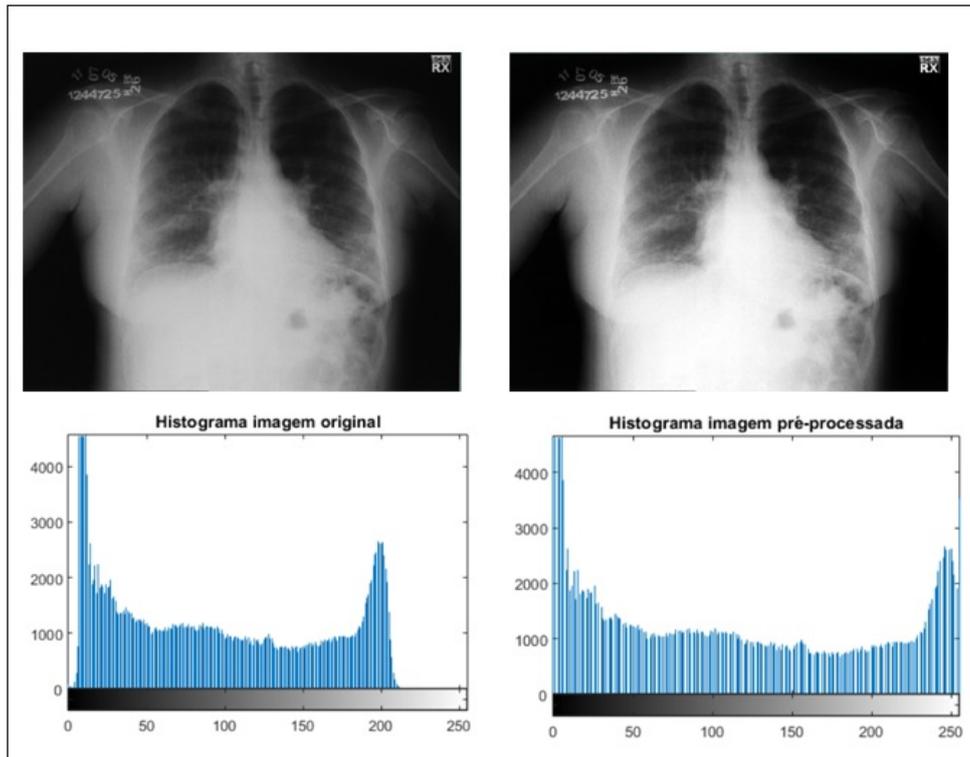


Figura 4.3: Imagem original e pré-processada e os respectivos histogramas.

cor dos pixels em escala de cinza $[0,255]$. Observa-se que para a primeira imagem utilizada, o histograma da imagem original apresenta variação dos valores de pixels no intervalo $[9, 211]$, enquanto no histograma da imagem pré-processada de $[0,255]$, logo, ocorreu o ajuste do contraste da imagem.

O histograma ajustado torna-se um elemento fundamental na aplicação do método de segmentação de Otsu na etapa de processamento [8], tradicional para imagens em tons de cinza. Por ser um método clássico, já existe a implementação no Matlab®R2015a. Verifica-se na Figura 4.4 a imagem binarizada com limiar do pixel de valor 121 após a seleção do botão “Método de Otsu”. Houve ainda a necessidade de se guardar a medida de efetividade do método em valores percentuais, que para esta imagem atingiu 79%.

A visualização desta medida pelo especialista fez-se necessário para comparação com a medida de efetividade advinda do método *fuzzy* proposto. Logo, fez-se necessário modificar o código do método de Otsu implementado no Matlab®R2015a para armazenar essa métrica, Figura 4.5.

Houve ainda a necessidade de se armazenar o valor do pixel considerado limiar para binarização da imagem. O armazenamento deste valor serviu para futuro confronto com o método *fuzzy* proposto, Figura 4.6.

A próxima etapa corresponde a geração do índice de intensidade de fibrose pulmonar (*IIFP*) que se inicia pela segmentação personalizada do pulmão esquerdo e

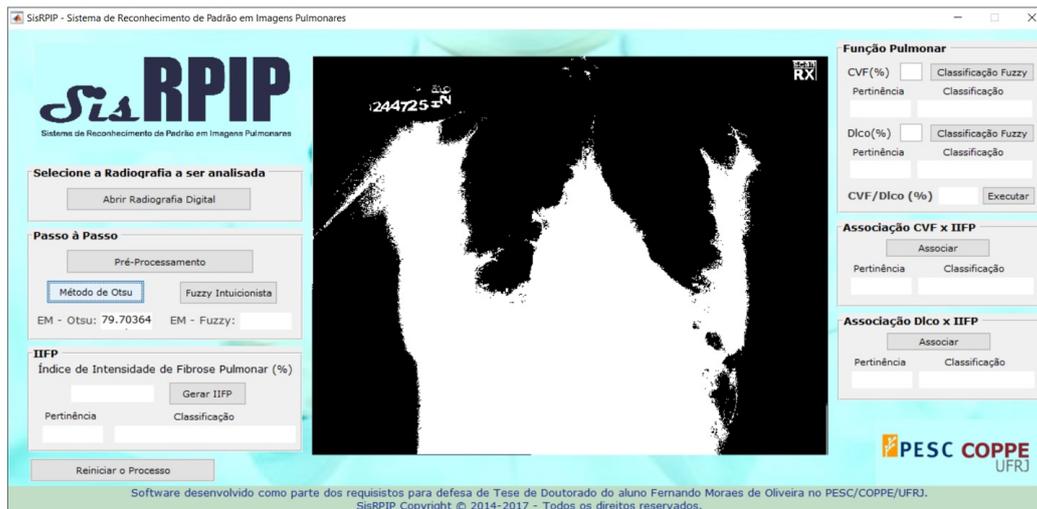


Figura 4.4: Imagem binarizada pelo método de Otsu.

```

% Calcula a effectiveness metric
if nargin >= 1
    if isfinite_maxval
        em = maxval/(sum(p.*((1:num_bins).^2)') - mu_t^2);
        fid = fopen('effectivenessmetric.txt','wt');
        fprintf(fid,'%f\n', em*100);
        fclose(fid);
    else
        em = 0;
    end
end

```

Figura 4.5: Código para armazenamento da efetividade do método.

direito pelo especialista, Figura 4.7.

A partir deste procedimento, o *IIFP* foi obtido em função da frequência relativa dos pixels brancos em relação aos pixels pretos após a segmentação pelo especialista, o que pode ser visualizado pelo código discriminado para o pulmão esquerdo, Figura 4.8.

Ao clicar no botão “Gerar *IIFP*”, visualiza-se o valor do *IIFP* de 4.6% para esta imagem. Segundo a metodologia exposta no item 4.5, a classificação em “Leve”, “Moderadamente Leve”, “Moderadamente Grave” e “Grave” foi obtida segundo os conjuntos *fuzzy* que para esta imagem teve classificação “Moderadamente Leve” com pertinência 0.15, Figura 4.9. Parte do código implementado pode ser visualizado na Figura 4.10.

A fidedignidade do *IIFP* pelo método de Otsu pôde ser calculada pela medida de nebulosidade em contraste com pertinências *fuzzy*, que tenta indicar o grau de nebulosidade de um conjunto *fuzzy*. Optou-se pela métrica euclidiana descrita na sessão 4.5 onde os elementos utilizados para o cálculo estão inseridos na Tabela

```

% Nome das variáveis similares aos do artigo original do Otsu.
p = counts / sum(counts);
omega = cumsum(p);
mu = cumsum(p .* (1:num_bins)');
mu_t = mu(end);
sigma_b_squared = (mu_t * omega - mu).^2 ./ (omega .* (1 - omega));

% Encontra a localização do valor máximo para sigma_b_squared.
maxval = max(sigma_b_squared);
isfinite_maxval = isfinite(maxval);

if isfinite_maxval
    idx = mean(find(sigma_b_squared == maxval));
    display(idx);
    % Normaliza o limiar para entre [0, 1].
    level = (idx - 1) / (num_bins - 1);
else
    level = 0.0;
end
else
    level = 0.0;
    isfinite_maxval = false;
end

```

Figura 4.6: Código para visualização do limiar pelo método de Otsu.

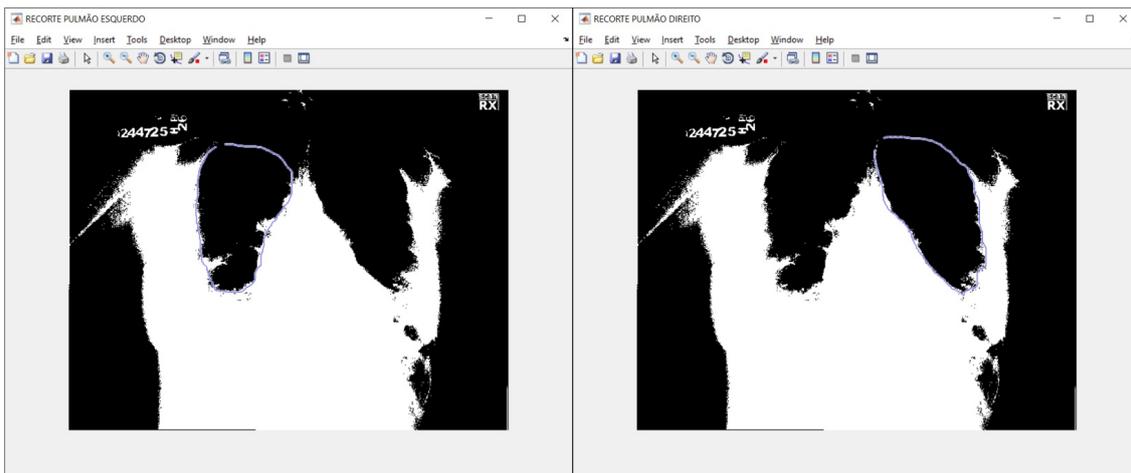


Figura 4.7: Segmentação personalizada pelo especialista.

4.1, tendo como resultados os valores de 0,0367, 0,5449 e 0,4189 para as categorias, LEVE, MODERADAMENTE LEVE e MODERADAMENTE GRAVE, respectivamente. A análise com o uso do operador de média ponderada e hierarquizada (OWA) atendeu a restrição da soma dos pesos, 0,09, 0,18, 0,18 e 0,55 e o intervalo fechado $[0,1]$, para as categorias LEVE, MODERADAMENTE LEVE, MODERADAMENTE GRAVE e GRAVE. Apesar do método de segmentação de Otsu ser usualmente utilizado para binarização de imagens em tons de cinza, ao dar continuidade para obter a classificação do *IIFP* não ocorreu reconhecimento do padrão GRAVE para nenhum dos 40 pacientes deste estudo.

```

% analise do pulmao esquerdo
pulmaoesquerdo = imfreehand;
Mascaraesquerdo = ~pulmaoesquerdo.createMask();
handles.pulmaoesquerdo(Mascaraesquerdo) = 0;
[handles.recorteesquerdo, rect] = imcrop(handles.pulmaoesquerdo);
imshow(handles.recorteesquerdo);
contBrancoesquerdo = 0;
for ii=1:size(handles.recorteesquerdo,1)
    for jj=1:size(handles.recorteesquerdo,2)
        pixel=handles.recorteesquerdo(ii,jj);
        if pixel==1 %contagem de pixeis brancos
            contBrancoesquerdo = contBrancoesquerdo +1;
        end
    end
end
display('Quant Pixeis Brancos Pulmao Esquerdo: ');
display(handles.QuantPBesquerdo);
contPretoesquerdo = 0;
for ii=1:size(handles.recorteesquerdo,1)
    for jj=1:size(handles.recorteesquerdo,2)
        pixel=handles.recorteesquerdo(ii,jj);
        if pixel==0 %contagem de pixeis pretos
            contPretoesquerdo = contPretoesquerdo +1;
        end
    end
end
end

```

Figura 4.8: Código implementado em Matlab®R2015a para o pulmão esquerdo.

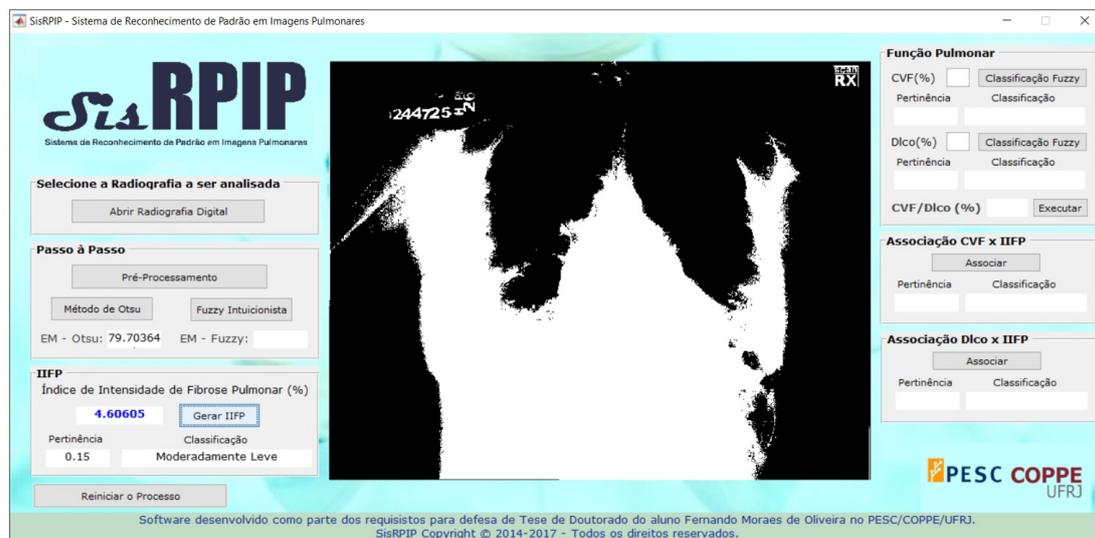


Figura 4.9: Tela do SisRPIP com o valor do *IIFP*, a classificação *fuzzy* e sua respectiva pertinência.

Tabela 4.1: Elementos para cálculo do grau de nebulosidade dos conjuntos *fuzzy* do *IIFP*.

Pertinência	Pertinência Complementar	Classificação <i>Fuzzy</i>
0,3700	0,6300	Leve

Continua na próxima página

Tabela 4.1 – *Continuação da Tabela 4.1.*

Pertinência	Pertinência Complementar	Classificação <i>Fuzzy</i>
0,3600	0,6400	Leve
0,4600	0,5400	Leve
0,4400	0,5600	Leve
0,0900	0,9100	Moderadamente Leve
0,3600	0,6400	Moderadamente Leve
0,0001	0,9999	Moderadamente Leve
0,4500	0,5500	Moderadamente Leve
0,0900	0,9100	Moderadamente Leve
0,2500	0,7500	Moderadamente Leve
0,1600	0,8400	Moderadamente Leve
0,1900	0,8100	Moderadamente Leve
0,3100	0,6900	Moderadamente Leve
0,1700	0,8300	Moderadamente Leve
0,0700	0,9300	Moderadamente Leve
0,3000	0,7000	Moderadamente Leve
0,2700	0,7300	Moderadamente Leve
0,0800	0,9200	Moderadamente Leve
0,1500	0,8500	Moderadamente Leve
0,0400	0,9600	Moderadamente Leve
0,3400	0,6600	Moderadamente Leve
0,3400	0,6600	Moderadamente Leve
0,2100	0,7900	Moderadamente Leve
0,1700	0,8300	Moderadamente Leve
0,3300	0,6700	Moderadamente Leve
0,0500	0,9500	Moderadamente Leve
0,3600	0,6400	Moderadamente Grave
0,3700	0,6300	Moderadamente Grave
0,2800	0,7200	Moderadamente Grave
0,4700	0,5300	Moderadamente Grave
0,0600	0,9400	Moderadamente Grave
0,0100	0,9900	Moderadamente Grave
0,1600	0,8400	Moderadamente Grave
0,0100	0,9900	Moderadamente Grave
0,3700	0,6300	Moderadamente Grave
0,3300	0,6700	Moderadamente Grave

Continua na próxima página

Tabela 4.1 – *Continuação da Tabela 4.1.*

Pertinência	Pertinência Complementar	Classificação <i>Fuzzy</i>
0,3300	0,6700	Moderadamente Grave
0,3400	0,6600	Moderadamente Grave
0,0700	0,9300	Moderadamente Grave
0,0600	0,9400	Moderadamente Grave

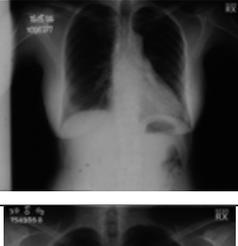
Os resultados para os 40 pacientes pelo método de segmentação de Otsu encontram-se na Tabela 4.2, discriminando-se paciente, imagem correspondente, limiar utilizado pelo método, métrica de efetividade e o *IIFP*.

Tabela 4.2: Síntese dos resultados do método de Otsu.

Paciente	Imagem	Limiar	Efetividade (%)	IIFP (%)
2		108	81	3,7220
3		116	81	6,5554
4		130	77	5,4201
5		113	85	2,1072
6		136	81	4,0064

Continua na próxima página

Tabela 4.2 – Continuação da Tabela 4.2.

Paciente	Imagem	Limiar	Efetividade (%)	IIFP (%)
7		109	80	2,6538
9		118	78	3,7179
12		119	83	6,5255
13		135	78	6,8774
15		110	79	2,0726
16		148	77	6,1270

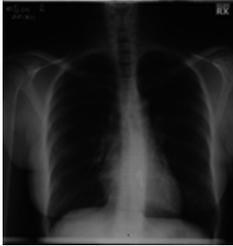
Continua na próxima página

Tabela 4.2 – Continuação da Tabela 4.2.

Paciente	Imagem	Limiar	Efetividade (%)	IIFP (%)
17		141	81	7,7631
18		123	79	8,0449
19		100	75	3,2611
21		122	79	3,5347
22		129	82	2,3809
23		126	81	3,4212

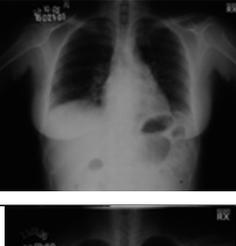
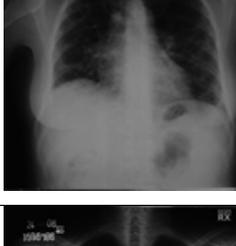
Continua na próxima página

Tabela 4.2 – Continuação da Tabela 4.2.

Paciente	Imagem	Limiar	Efetividade (%)	IIFP (%)
24		131	77	5,2425
25		109	79	3,4762
26		97	75	2,3085
27		135	82	8,6498
28		105	79	4,2762
29		143	82	7,9724

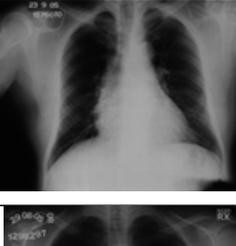
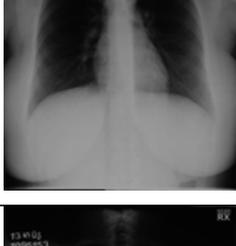
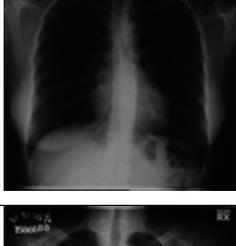
Continua na próxima página

Tabela 4.2 – Continuação da Tabela 4.2.

Paciente	Imagem	Limiar	Efetividade (%)	IIFP (%)
30		113	82	3,1135
31		118	79	3,1912
32		117	80	9,4835
33		131	83	3,7575
34		134	79	6,6924
35		129	82	6,6601

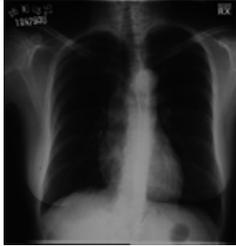
Continua na próxima página

Tabela 4.2 – Continuação da Tabela 4.2.

Paciente	Imagem	Limiar	Efetividade (%)	IIFP (%)
36		112	78	3,5549
37		137	83	6,6553
39		131	79	7,7164
40		135	78	3,8904
43		101	79	2,9949
44		124	86	5,3488

Continua na próxima página

Tabela 4.2 – Continuação da Tabela 4.2.

Paciente	Imagem	Limiar	Efetividade (%)	IIFP (%)
45		113	78	3,3556
46		127	80	3,4786
47		109	77	3,0082
48		119	80	7,7619
49		117	76	3,8553

Apesar dos esforços para processos de segmentação de imagens, ainda há ausência de um número razoável de métodos e resultados julgados acurados, o que conduz à procura de alternativas para segmentação de radiografias simples de tórax digitais.

4.2 Segmentação pelo conjunto intuicionista *fuzzy*

Similarmente ao método de Otsu, as etapas iniciais foram mantidas até que o especialista tenha selecionado o botão “Fuzzy Intuicionista” no SisRPIP, Figura 4.11, opção tratada pelos conjuntos intuicionistas *fuzzy* segundo descrição metodológica

```

% BOTÃO PARA CALCULAR O INDICE DE INTENSIDADE DE FIBROSE PULMONAR SEGUNDO
% OS CONJUNTOS FUZZY
if (handles.xIIFP>=1) && (handles.xIIFP<4)
    r1 = 0; y = 0; r2 = 0; y1 = 0; y2 = 1; x1 = 1; x2 = 4;
    handles.pertinencia1IIFP=0;
    handles.pertinencia2IIFP=0;
    r1 = (y2 - y1)/(x2 - x1); % coeficiente angular
    b = y1 - (r1 * x1);
    handles.pertinencia1IIFP = (r1 * handles.xIIFP) + b;
    r2 = -((y2 - y1)/(x2 - x1)); % coeficiente angular
    b = y2 - (r2 * x1);
    handles.pertinencia2IIFP = (r2 * handles.xIIFP) + b;
    handles.pertinenciaIIFP = min(pertinencia1IIFP, pertinencia2IIFP);
    if (handles.pertinenciaIIFP == handles.pertinencia1IIFP)
        handles.classificacaoIIFP = 'Leve';
    else
        handles.classificacaoIIFP = 'Moderadamente Leve';
    end
end
end

```

Figura 4.10: Código implementado em Matlab®R2015a para o pulmão esquerdo.

exposta na seção 3.4.2.

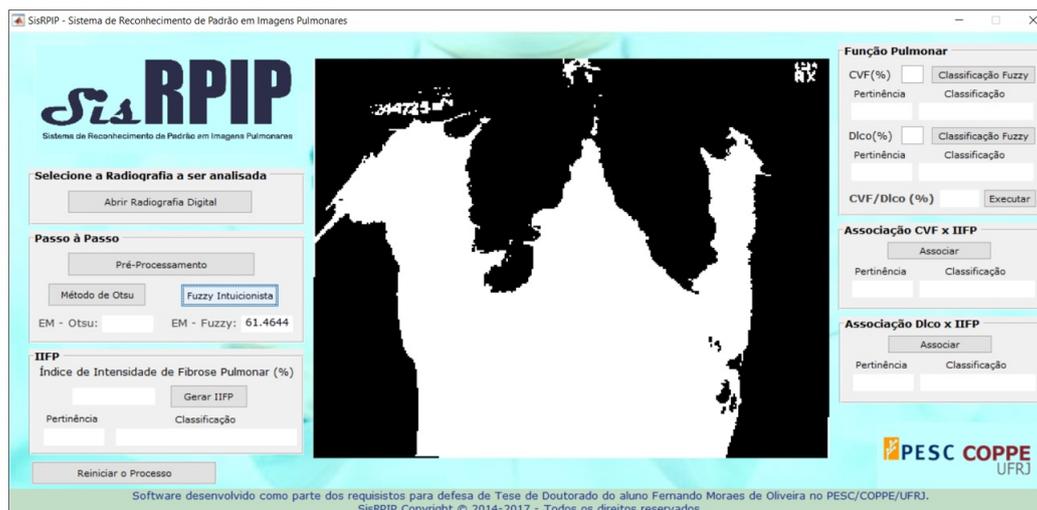


Figura 4.11: Imagem binarizada pelos conjuntos intuicionistas *fuzzy*.

A implementação computacional do método pelos conjuntos intuicionistas *fuzzy* para esta Tese foi codificada no Matlab®R2015a. De forma análoga ao método de Otsu, a próxima etapa correspondeu a geração do *IIFP* que se inicia pela segmentação personalizada do pulmão esquerdo e direito pelo especialista (Figura 4.12), sendo obtido em função da frequência relativa dos pixels brancos em relação aos pixels pretos.

Exemplificando-se, ao clicar no botão "Gerar *IIFP*", visualiza-se o valor de 4.6% para esta imagem, porém com a segmentação oriunda do método dos conjuntos intuicionistas *fuzzy*, obtendo-se classificação "Moderadamente Leve" com pertinência 0,15, pelos conjuntos *fuzzy*, Figura 4.13.

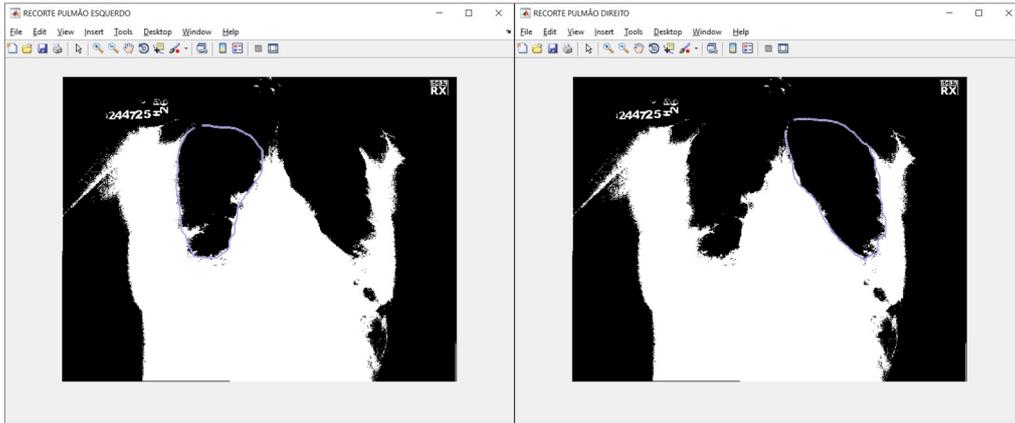


Figura 4.12: Segmentação personalizada pelo especialista.

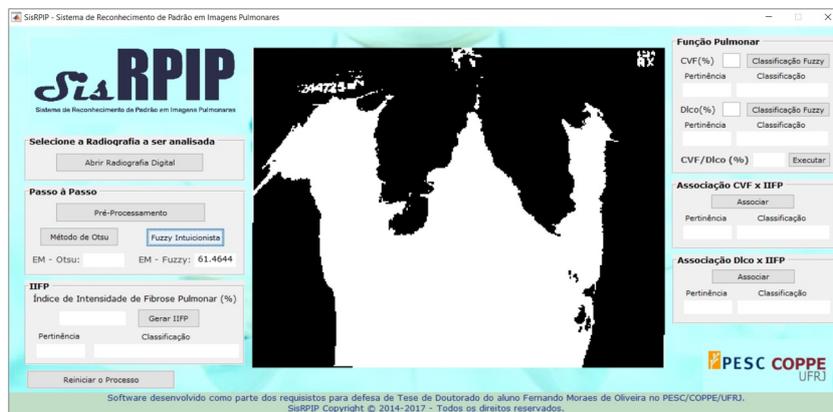


Figura 4.13: Tela do SisRPIP com o valor do *IIFP*, a classificação fuzzy e sua respectiva pertinência.

Similarmente ao método de Otsu, os resultados *fuzzy* para os 40 pacientes encontram-se na Tabela 4.3.

Tabela 4.3: Síntese dos resultados do método sob a ótica dos conjuntos intuicionistas *fuzzy*.

Paciente	Imagem	Limiar	IIFP (%)
2		80	5,5036

Continua na próxima página

Tabela 4.3 – *Continuação da Tabela 4.3.*

Paciente	Imagem	Limiar	IIFP (%)
3		97	13,7071
4		157	3,1153
5		96	2,8582
6		111	5,2932
7		162	2,6098
9		110	2,7167
12		118	4,5037

Continua na próxima página

Tabela 4.3 – Continuação da Tabela 4.3.

Paciente	Imagem	Limiar	IIFP (%)
13		115	2,4389
15		42	6,1281
16		168	5,1856
17		154	3,5896
18		138	6,9869
19		78	4,6276

Continua na próxima página

Tabela 4.3 – Continuação da Tabela 4.3.

Paciente	Imagem	Limiar	IIFP (%)
21		153	1,9882
22		186	4,5409
23		213	2,7605
24		156	4,1325
25		143	1,5787
26		63	4,2850

Continua na próxima página

Tabela 4.3 – Continuação da Tabela 4.3.

Paciente	Imagem	Limiar	IIFP (%)
27		135	10,1037
28		58	4,4352
29		169	9,1739
30		107	2,8331
31		167	3,2206
32		138	5,55995

Continua na próxima página

Tabela 4.3 – Continuação da Tabela 4.3.

Paciente	Imagem	Limiar	IIFP (%)
33		169	4,9526
34		175	5,1565
35		196	11,1358
36		113	3,2702
37		199	2,8946
39		178	4,4229

Continua na próxima página

Tabela 4.3 – Continuação da Tabela 4.3.

Paciente	Imagem	Limiar	IIFP (%)
40		195	2,45474
43		88	3,4213
44		112	6,0278
45		96	2,9797
46		116	2,7638
47		76	8,5794

Continua na próxima página

Tabela 4.3 – Continuação da Tabela 4.3.

Paciente	Imagem	Limiar	IIFP (%)
48		119	7,5407
49		117	2,06723

A validação do método sob a ótica dos conjuntos intuicionistas *fuzzy* foi realizada em função da entropia deste conjunto, que corresponde a uma medida que agrega a entropia *fuzzy* $E_{fuzzy}(A)$ e a entropia intuicionista *fuzzy* $E_{intuicionista}(A)$ conforme mencionado na sessão 3.4.2. O termo $E_{fuzzy}(A)$ descreve o quanto difuso é o conjunto intuicionista *fuzzy*, sendo que em relação a seus elementos predomina a condição de igualdade da pertinência e não pertinência delimitada por 0,5, isto é, $\mu_A(x) = \nu_A(x) = \frac{1}{2}$. A $E_{intuicionista}(A)$ consiste de dois componentes, uma que expressa o grau de nebulosidade e a outra o de intuição. A implementação para o cálculo da entropia intuicionista *fuzzy* sob a ótica de De Luca e Termini, E_{LT}^{CIF} , foi realizada no Matlab®R2015a para cada imagem. O código pode ser visualizado na Figura 4.14 e os resultados encontram-se sumarizados na Tabela 4.4.

Tabela 4.4: Síntese dos resultados do cálculo da entropia.

Paciente	E_{fuzzy}	$E_{intuicionista}$	E_{LT}^{CIF} (%)
2	1,1773	0,4889	1,6662
3	1,1738	0,4812	1,6550
4	1,1967	0,3956	1,5923
5	1,1604	0,5338	1,6942
6	1,1132	0,2747	1,3880
7	1,1810	0,4594	1,6404
9	1,1763	0,4112	1,5876
12	1,1636	0,4311	1,5947
13	1,1169	0,2597	1,3765
15	1,1829	0,4596	1,6425

Continua na próxima página

Tabela 4.4 – Continuação da Tabela 4.4.

Paciente	E_{fuzzy}	$E_{intuicionista}$	EC_{LT}^{IF} (%)
16	1,0996	0,2351	1,3347
17	1,0593	0,2494	1,3086
18	1,1391	0,3074	1,4465
19	1,1862	0,4615	1,6477
21	1,1577	0,3167	1,4744
22	1,1112	0,2967	1,4079
23	1,1345	0,3100	1,4445
24	1,1162	0,2627	1,3789
25	1,1815	0,4566	1,6380
26	1,1807	0,4461	1,6268
27	1,0753	0,2748	1,3501
28	1,3501	0,4216	1,6075
29	1,0468	0,2412	1,2880
30	1,1525	0,3965	1,5490
31	1,1124	0,3066	1,4190
32	1,1599	0,3934	1,5533
33	1,0743	0,2817	1,3560
34	1,1096	0,2642	1,3738
35	1,0948	0,2985	1,3933
36	1,1858	0,4449	1,6307
37	1,0585	0,2727	1,3313
39	1,1343	0,2938	1,4281
40	1,0871	0,2531	1,3401
43	1,1764	0,4734	1,6497
44	1,1169	0,3649	1,4818
45	1,1834	0,4707	1,6541
46	1,1211	0,2974	1,4185
47	1,1910	0,4345	1,6255
48	1,1523	0,3131	1,4654
49	1,1822	0,3833	1,5654

A medida de entropia intuicionista $E_{intuicionista}$ é considerada normalizada e mede o grau de intuição do conjunto intuicionista *fuzzy*, enquanto a entropia *fuzzy* E_{fuzzy} descreve a nebulosidade intrínseca dos conjuntos intuicionistas *fuzzy*. Verifica-se na Tabela 4.4 que a imagem do paciente 5 foi a única que apresentou valor de $E_{intuicionista} = 0,5338$, o que infere a igualdade entre a pertinência e a não pertinên-

```

for i=1:TamanhoFundo
    entropiaFundo = entropiaFundo + (MaFundo(i)*log(MaFundo(i)))
    + (VaFundo(i)*log(VaFundo(i)))
    - ((MaFundo(i)+VaFundo(i))*log(MaFundo(i)+VaFundo(i)));
end
entropiaFundo = -1*(entropiaFundo/double((TamanhoFundo*log(2))));
for i=1:TamanhoObjeto
    entropiaObjeto = entropiaObjeto + (MaObjeto(i)*log(MaObjeto(i)))
    + (VaObjeto(i)*log(VaObjeto(i)))
    - ((MaObjeto(i)+VaObjeto(i))*log(MaObjeto(i)+VaObjeto(i)));
end
entropiaObjeto = -1*(entropiaObjeto/double((TamanhoObjeto*log(2))));
entropiafuzzy = entropiaFundo+entropiaObjeto;
display(entropiafuzzy);
for i=1:TamanhoFundo
    entropiaIntFundo = entropiaIntFundo + (1-(MaFundo(i)+VaFundo(i)));
end
entropiaintuicionistaFundo = entropiaIntFundo/TamanhoFundo;
for i=1:TamanhoObjeto
    entropiaIntObjeto = entropiaIntObjeto + (1-(MaObjeto(i)+VaObjeto(i)));
end
entropiaintuicionistaObjeto = entropiaIntObjeto/TamanhoObjeto;
entropiaintuicionista = entropiaintuicionistaFundo+entropiaintuicionistaObjeto;
display(entropiaintuicionista);
display(entropiafuzzy+entropiaintuicionista);

```

Figura 4.14: Implementação no Matlab®R2015a para cálculo da entropia dos conjuntos intuicionistas *fuzzy*.

cia. Observa-se ainda que 20 imagens dentre as 40 apresentaram valor de $E_{intuicionista}$ abaixo de 30% e 14 acima de 40%, valores significativos segundo Vlachos e Sergiadis [57]. Este resultado mostra que a segmentação sob a ótica dos conjuntos intuicionistas *fuzzy* minimizou a entropia intuicionista *fuzzy* tendo como referência De Luca e Termini [64], E_{LT}^{CIF} .

Analogamente ao método de Otsu, verificou-se a fidedignidade do *IIFP* sob a ótica dos conjuntos intuicionistas *fuzzy*, cujos valores estão discriminados na Tabela 4.6.

Tabela 4.5: Elementos para cálculo do grau de nebulosidade dos conjuntos *fuzzy* do *IIFP* sob a ótica dos conjuntos intuicionistas *fuzzy*.

Pertinência	Pertinência Complementar	Classificação <i>fuzzy</i>
0,6200	0,3800	Moderadamente Leve
0,0000	1,0000	Grave
0,7100	0,2900	Moderadamente Leve
0,0000	1,0000	Leve
0,7000	0,3000	Moderadamente Leve
0,5400	0,4600	Moderadamente Leve

Continua na próxima página

Tabela 4.5 – *Continuação da Tabela 4.6.*

Pertinência	Pertinência Complementar	Classificação <i>fuzzy</i>
0,5700	0,4300	Moderadamente Leve
0,8700	0,1300	Moderadamente Leve
0,5900	0,4100	Moderadamente Leve
0,5300	0,4700	Moderadamente Grave
0,6900	0,3100	Moderadamente Leve
0,5900	0,4100	Moderadamente Leve
0,5100	0,4900	Moderadamente Grave
0,8400	0,1600	Moderadamente Leve
0,0000	1,0000	Leve
0,8600	0,1400	Moderadamente Leve
0,5900	0,4100	Moderadamente Leve
0,7600	0,2400	Moderadamente Leve
0,8100	0,1900	Leve
0,9300	0,0700	Moderadamente Leve
0,0000	1,0000	Grave
0,8900	0,1100	Moderadamente Leve
0,7100	0,2900	Moderadamente Grave
0,6100	0,3900	Moderadamente Leve
0,7400	0,2600	Moderadamente Leve
0,6100	0,3900	Moderadamente Leve
0,6300	0,3700	Moderadamente Leve
0,6100	0,3900	Moderadamente Leve
0,0000	1,0000	Grave
0,7600	0,2400	Moderadamente Leve
0,6300	0,3700	Moderadamente Leve
0,8900	0,1100	Moderadamente Leve
0,5200	0,4800	Leve
0,8100	0,1900	Moderadamente Leve
0,5100	0,4900	Moderadamente Grave
0,6600	0,3400	Moderadamente Leve
0,5900	0,4100	Moderadamente Leve
1,0000	0,1400	Moderadamente Grave
0,8900	0,1100	Moderadamente Grave
0,6400	0,3600	Leve

Na validação dos resultados também foi adotada a métrica euclidiana descrita na

sessão 3.4.2, tendo como resultados os valores 0,1412, 0,4304, 0,2058 e 0,9526 para as categorias, LEVE, MODERADAMENTE LEVE, MODERADAMENTE GRAVE e GRAVE, respectivamente. Enfatiza-se que nesta opção foi reconhecido o padrão do acometimento pulmonar pela esclerose sistêmica (ES) de todas as categorias dos conjuntos *fuzzy*, o que ressalta a sensibilidade do método. A análise com o uso do operador OWA também atendeu a restrição da soma dos pesos, 0,09, 0,18, 0,18 e 0,55 e o intervalo fechado $[0, 1]$, para as categorias LEVE, MODERADAMENTE LEVE, MODERADAMENTE GRAVE e GRAVE.

4.3 Validação dos métodos implementados ao reconhecer padrão do acometimento pulmonar

O índice de intensidade de fibrose pulmonar (*IIFP*) deve estar associado as variáveis advindas do exame de função pulmonar, capacidade vital forçada (*CVF*) e capacidade de difusão do monóxido de carbono (D_{LCO}). Essa associação foi validada pelas pertinências dos conjuntos *fuzzy* do *IIFP* segundo a análise da concordância atribuída a Bland Altman, descrito na sessão 3.5.

4.3.1 Afinidade pelo método de Otsu entre *IIFP*, *CVF* e D_{LCO}

Primeiramente o *IIFP* foi obtido após a segmentação da imagem usando o método de Otsu e então foram atribuídos ponderadores às pertinências segundo a escala ordinal em métodos estatísticos não paramétricos e optou-se em avaliar a associação entre o *IIFP* x *CVF* e *IIFP* x D_{LCO} de forma plena, pois cada ponderador da média hierarquizada (OWA), discrimina as categorias classificatórias, sendo adotado os mesmos pesos da sessão 4.2, 0,09, 0,18, 0,18 e 0,55, para o *IIFP* e, de forma análoga, para as variáveis *CVF* e D_{LCO} foram adotados os pesos 0,16 para LEVE, 0,33 para MODERADO e 0,5 para GRAVE. A Tabela 4.6 apresenta as pertinências e pertinências ponderadas das variáveis *IIFP*, *CVF* e D_{LCO} utilizadas para o cálculo da análise da concordância atribuída a Bland Altman.

Tabela 4.6: Pertinências e pertinências ponderadas utilizadas para o cálculo da concordância atribuída a Bland Altman com *IIFP* pelo método de Otsu.

Paciente	$\mu_{IIFP}(x)$	$\mu_{IIFP}(x) * w$	$\mu_{CVF}(x)$	$\mu_{CVF}(x) * w$	$\mu_{D_{LCO}}(x)$	$\mu_{D_{LCO}}(x) * w$
2	0,0900	0,0225	0,3000	0,0990	0,2000	0,1000

Continua na próxima página

Tabela 4.6 – Continuação da Tabela 4.6.

Paciente	$\mu_{IIFP}(x)$	$\mu_{IIFP}(x) * w$	$\mu_{CVF}(x)$	$\mu_{CVF}(x) * w$	$\mu_{D_{LCO}}(x)$	$\mu_{D_{LCO}}(x) * w$
3	0,3600	0,0900	0,2000	0,1000	1,0000	0,5000
4	0,3600	0,0900	0,2000	0,0660	0,5000	0,1650
5	0,3700	0,0370	0,2000	0,0320	0,3000	0,0480
6	0,0001	0,0000	1,0000	0,1600	0,3000	0,0480
7	0,4500	0,1125	0,5000	0,0800	0,5000	0,0800
9	0,0900	0,0225	0,2000	0,0660	0,5000	0,1650
12	0,3700	0,0925	1,0000	0,5000	0,5000	0,0800
13	0,2800	0,0700	0,5000	0,0800	0,5000	0,2500
15	0,3600	0,0360	0,3500	0,1155	0,1000	0,0330
16	0,4700	0,1175	0,1000	0,0160	0,5000	0,2500
17	0,0600	0,0150	1,0000	0,5000	1,0000	0,5000
18	0,0100	0,0025	0,5000	0,0800	1,0000	0,5000
19	0,2500	0,0625	0,3000	0,0990	0,5000	0,1650
21	0,1600	0,0400	1,0000	0,1600	1,0000	0,1600
22	0,4600	0,0460	1,0000	0,1600	0,1000	0,0500
23	0,1900	0,0475	1,0000	0,1600	0,5000	0,0800
24	0,3100	0,0775	0,4500	0,0720	0,2000	0,0320
25	0,1700	0,0425	1,0000	0,1600	1,0000	0,1600
26	0,4400	0,0440	1,0000	0,1600	0,2000	0,0320
27	0,1600	0,0400	1,0000	0,5000	1,0000	0,5000
28	0,0700	0,0175	0,1000	0,0330	0,2000	0,0660
29	0,0100	0,0025	1,0000	0,5000	0,5000	0,0800
30	0,3000	0,0750	1,0000	0,1600	0,4000	0,0640
31	0,2700	0,0675	0,0500	0,0165	0,4000	0,1320
32	0,3700	0,0925	0,5000	0,1650	0,4000	0,1320
33	0,0800	0,0200	1,0000	0,1600	0,1000	0,0160
34	0,3300	0,0825	1,0000	0,3300	0,2000	0,1000
35	0,3300	0,0825	1,0000	0,5000	1,0000	0,5000
36	0,1500	0,0375	0,4000	0,2000	1,0000	0,5000
37	0,3400	0,0850	1,0000	0,5000	0,2000	0,0320
39	0,0700	0,0175	0,2000	0,0660	1,0000	0,3300
40	0,0400	0,0100	1,0000	0,1600	1,0000	0,1600
43	0,3400	0,0850	1,0000	0,1600	1,0000	0,1600
44	0,3400	0,0850	1,0000	0,1600	0,5000	0,2500
45	0,2100	0,0525	1,0000	0,1600	1,0000	0,1600

Continua na próxima página

Tabela 4.6 – Continuação da Tabela 4.6.

Paciente	$\mu_{IIFP}(x)$	$\mu_{IIFP}(x) * w$	$\mu_{CVF}(x)$	$\mu_{CVF}(x) * w$	$\mu_{D_{LCO}}(x)$	$\mu_{D_{LCO}}(x) * w$
46	0,1700	0,0425	1,0000	0,1600	1,0000	0,1600
47	0,3300	0,0825	1,0000	0,1600	0,4000	0,0640
48	0,0600	0,0150	1,0000	0,1600	1,0000	0,1600
49	0,0500	0,0125	1,0000	0,1600	1,0000	0,1600

Os valores da média das diferenças, \bar{D} , entre as pertinências ponderadas do *IIFP* e do *CVF* e os respectivos desvios padrões, S_D , assumiram valores de 0,1301 e 0,1491 e no caso do *IIFP* e D_{LCO} foram encontrados os valores 0,1263 e 0,1564, respectivamente.

O intervalo de confiança para o limite de concordância de Bland Altman para o *IIFP* x *CVF* e *IIFP* x D_{LCO} , foram obtidos de acordo com a expressão descrita em 3.5 e podem ser visualizados na Figura 4.15.

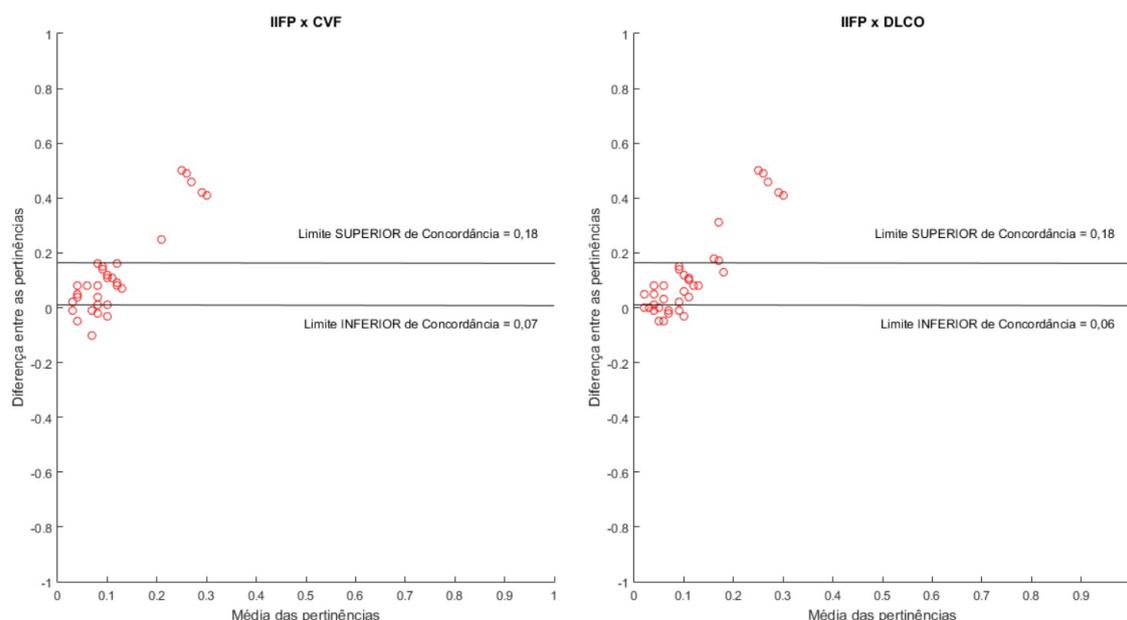


Figura 4.15: Gráfico de dispersão do *IIFP* x *CVF* e *IIFP* x D_{LCO} com *IIFP* pelo método de Otsu.

Percebe-se que, dos 40 pacientes, 6 (15%) estão aquém do limite inferior e 7 (17,5%) acima do limite superior do intervalo de confiança para os limites de concordância na interação entre *IIFP* e *CVF*, enquanto entre *IIFP* e D_{LCO} , 9 (22,5%) ficaram abaixo e 6 (15%) acima.

4.3.2 Afinidade pelos conjuntos intuicionistas *fuzzy* entre *IIFP*, *CVF* e *D_{LCO}*

De forma análoga a seção anterior, porém dessa vez com o *IIFP* obtido após a segmentação sob a ótica dos conjuntos intuicionistas *fuzzy* (CIF), a Tabela 4.7 mostra as pertinências e pertinências ponderadas das mesmas variáveis, *IIFP*, *CVF* e *D_{LCO}*.

Tabela 4.7: Pertinências e pertinências ponderadas utilizadas para o cálculo da concordância atribuída a Bland Altman com *IIFP* sob a ótica dos CIF.

Paciente	$\mu_{IIFP}(x)$	$\mu_{IIFP}(x) * w$	$\mu_{CVF}(x)$	$\mu_{CVF}(x) * w$	$\mu_{D_{LCO}}(x)$	$\mu_{D_{LCO}}(x) * w$
2	0,3800	0,0950	0,3000	0,0990	0,2000	0,1000
3	1,0000	0,4000	0,2000	0,1000	1,0000	0,5000
4	0,2900	0,0725	0,2000	0,0660	0,5000	0,1650
5	1,0000	0,1000	0,2000	0,0320	0,3000	0,0480
6	0,3000	0,0750	1,0000	0,1600	0,3000	0,0480
7	0,4600	0,1150	0,5000	0,0800	0,5000	0,0800
9	0,4300	0,1075	0,2000	0,0660	0,5000	0,1650
12	0,1300	0,0325	1,0000	0,5000	0,5000	0,0800
13	0,4100	0,1025	0,5000	0,0800	0,5000	0,2500
15	0,4700	0,1175	0,3500	0,1155	0,1000	0,0330
16	0,3100	0,0775	0,1000	0,0160	0,5000	0,2500
17	0,4100	0,1025	1,0000	0,5000	1,0000	0,5000
18	0,4900	0,1225	0,5000	0,0800	1,0000	0,5000
19	0,1600	0,0400	0,3000	0,0990	0,5000	0,1650
21	1,0000	0,1000	1,0000	0,1600	1,0000	0,1600
22	0,1400	0,0350	1,0000	0,1600	0,1000	0,0500
23	0,4100	0,1025	1,0000	0,1600	0,5000	0,0800
24	0,2400	0,0600	0,4500	0,0720	0,2000	0,0320
25	0,1900	0,0190	1,0000	0,1600	1,0000	0,1600
26	0,0700	0,0175	1,0000	0,1600	0,2000	0,0320
27	1,0000	0,4000	1,0000	0,5000	1,0000	0,5000
28	0,1100	0,0275	0,1000	0,0330	0,2000	0,0660
29	0,2900	0,0725	1,0000	0,5000	0,5000	0,0800
30	0,3900	0,0975	1,0000	0,1600	0,4000	0,0640
31	0,2600	0,0650	0,0500	0,0165	0,4000	0,1320
32	0,3900	0,0975	0,5000	0,1650	0,4000	0,1320

Continua na próxima página

Tabela 4.7 – Continuação da Tabela 4.6.

Paciente	$\mu_{IIFP}(x)$	$\mu_{IIFP}(x) * w$	$\mu_{CVF}(x)$	$\mu_{CVF}(x) * w$	$\mu_{D_{LCO}}(x)$	$\mu_{D_{LCO}}(x) * w$
33	0,3700	0,0925	1,0000	0,1600	0,1000	0,0160
34	0,3900	0,0975	1,0000	0,3300	0,2000	0,1000
35	1,0000	0,4000	1,0000	0,5000	1,0000	0,5000
36	0,2400	0,0600	0,4000	0,2000	1,0000	0,5000
37	0,3700	0,0925	1,0000	0,5000	0,2000	0,0320
39	0,1100	0,0275	0,2000	0,0660	1,0000	0,3300
40	0,4800	0,0480	1,0000	0,1600	1,0000	0,1600
43	0,1900	0,0475	1,0000	0,1600	1,0000	0,1600
44	0,4900	0,1225	1,0000	0,1600	0,5000	0,2500
45	0,3400	0,0850	1,0000	0,1600	1,0000	0,1600
46	0,4100	0,1025	1,0000	0,1600	1,0000	0,1600
47	0,1400	0,0350	1,0000	0,1600	0,4000	0,0640
48	0,1100	0,0275	1,0000	0,1600	1,0000	0,1600
49	0,3600	0,0360	1,0000	0,1600	1,0000	0,1600

Os valores da média das diferenças, \bar{D} , entre as pertinências ponderadas do *IIFP* e do *CVF* e os respectivos desvios padrões, S_D , assumiram valores de 0,0837 e 0,1429 e no caso do *IIFP* e D_{LCO} foram encontrados os valores 0,0799 e 0,1204, respectivamente.

O intervalo de confiança para o limite de concordância de Bland Altman para o *IIFP* x *CVF* e *IIFP* x D_{LCO} , foram obtidos de acordo com a expressão descrita em 3.5 e podem ser visualizados na Figura 4.16.

Deste modo, dos 40 pacientes, nenhum deles está aquém do limite inferior e 5 (12,5%) estão acima do limite superior do intervalo de confiança para os limites de concordância na interação entre *IIFP* e *CVF*, enquanto entre *IIFP* e D_{LCO} , apenas 1 (2,5%) ficou abaixo e 7 (17,5%) acima.

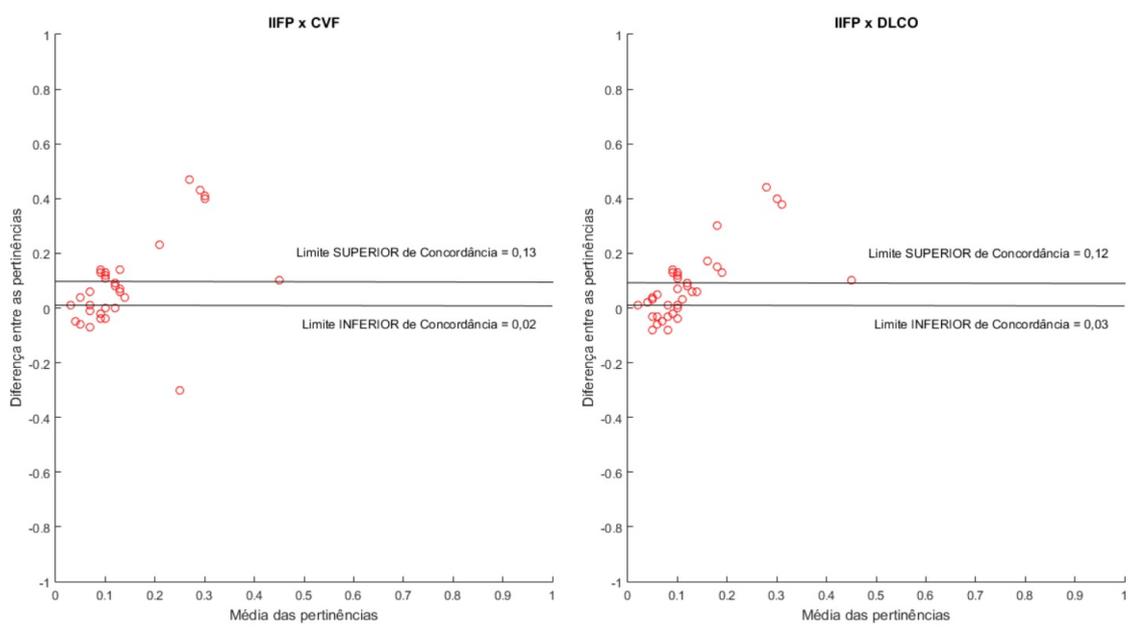


Figura 4.16: Gráfico de dispersão do $IIFP$ x CVF e $IIFP$ x D_{LCO} com $IIFP$ sob a ótica dos CIF.

Capítulo 5

Considerações Finais

À partir da digitalização da radiografia simples de tórax de pacientes diagnosticados com esclerose sistêmica (ES) pelo software scanRX, descrito na seção 3.2, realizou-se o ajuste da imagem de radiografia simples de tórax na etapa de pré-processamento com o intuito de tornar a imagem mais nítida com realce da profundidade de cor dos pixels, etapa precedente a segmentação.

Na etapa subsequente, foi cumprida a segmentação de imagens, tanto pelo método clássico de Otsu, quanto pelo método sob a ótica dos conjuntos intuicionistas *fuzzy*. A proposta do método *fuzzy* mostrou-se mais acurado, uma vez que cumpriu com maior eficiência a geração do índice de intensidade de fibrose pulmonar (*IIFP*) em função da segmentação pelo especialista após a binarização da imagem segmentada. A aferição da entropia pelo grau de nebulosidade para o *IIFP* advindo do método de Otsu, gerou resultado melhor apenas para a categoria LEVE, enquanto que pelo método sob a ótica dos conjuntos intuicionistas *fuzzy* (CIF) gerou melhor resultado nas demais classes. A categoria GRAVE ficou prejudica no cálculo da entropia, uma vez que os 3 (três) pacientes foram classificados com pertinência máxima. Enfatiza-se que o método de segmentação de Otsu não percebeu o reconhecimento da categoria GRAVE para o *IIFP*, mas a delimitação do suporte para os conjuntos *fuzzy* poderia não estar otimizado, o que propicia a perda na qualidade classificatória e que induz que sejam realizadas novas simulações alterando os limites do suporte dos conjuntos *fuzzy* do *IIFP*, mesmo sob a ótica dos CIF.

Uma vez que havia necessidade de verificar a associação entre o *IIFP* e as variáveis capacidade vital forçada (*CVF*) e capacidade de difusão do monóxido de carbono (D_{LCO}) dos exames de função pulmonar, optou-se em obter valores de pertinência e sua correspondente classificação para cada uma dessas variáveis segundo os conjuntos *fuzzy*. A associação dos pares de atributos *IIFP* x *CVF* e *IIFP* x D_{LCO} foi realizada segundo sistema lógico de inferência *fuzzy*, antecedente/consequente (Se..Então) o que levou ao reconhecimento do padrão do acometimento pulmonar em pacientes com esclerose sistêmica (ES). Coube ainda aferir a concordância dessas

associações pela análise de concordância de Bland Altman.

A avaliação da concordância entre os pares de variáveis, que deveriam aferir a semelhança de afinidades, efetivou-se pela inclusão nesta Tese da obtenção dos limites de concordância e seus intervalos de confiança de Bland Altman. Nesta opção, as pertinências do *IIFP* obtidas após a segmentação sob a ótica dos CIF, mostraram-se mais adequadas, tanto na relação *IIFP* x *CVF* quanto na *IIFP* x *D_{LCO}*. Na primeira relação, sob a ótica dos CIF, não ocorreu nenhum caso abaixo do limite inferior e apenas 12,5% acima do limite superior, enquanto que as pertinências do *IIFP* obtidas após a segmentação pelo método de Otsu, ficaram 15% aquém do limite inferior e 17,5% acima do limite superior. Na segunda relação, o *IIFP* advindo dos CIF apresentou apenas 2,5% abaixo do limite inferior e 17,5% acima do limite superior, enquanto que as pertinências do *IIFP* pelo método de Otsu ficaram 22,5% abaixo do inferior e 15% acima do superior, o que mostra a óbvia associação entre o *IIFP* e as variáveis advindas dos exames de função pulmonar, quando o *IIFP* é tratado pelos CIF, com maior relevância de associação entre *IIFP* e *CVF*.

Ressalta-se que o *IIFP* foi construído a partir da frequência relativa dos pixels brancos obtidos da radiografia simples de tórax digitalizada. Deste modo, a proposição deste índice atende como um facilitador do acompanhamento clínico do paciente diagnosticado com ES, quando esta acomete o pulmão. Esta é uma alternativa que minimiza custo nos atendimentos clínicos, pois utiliza radiografia simples de tórax digital ao invés de tomografia computadorizada (TC), e se mostra de fácil implementação, uma vez que o SisRPIP – Sistema de reconhecimento de padrão em imagens pulmonares necessita de poucos recursos computacionais.

Referências Bibliográficas

- [1] LIMA, T. R. D. L. “Avaliação da Função Pulmonar, Capacidade Funcional, Equilíbrio e Postura em Pacientes com Esclerodermia”, *Rio de Janeiro: Programa de Pós-Graduação Em Ciências Da Reabilitação-Centro Universitário Augusto Motta*, 2014.
- [2] SIQUEIRA, M. D. “Reconhecimento automático de padrões em imagens ecocardiográficas”, *Porto Alegre: PPGC-UFRGS*, 2010.
- [3] CHIZZOLINI, C., BREMBILLA, N. C., MONTANARI, E., et al. “Fibrosis and immune dysregulation in systemic sclerosis”, *Autoimmunity reviews*, v. 10, n. 5, pp. 276–281, 2011.
- [4] STICHERLING, M. “Systemic sclerosis—dermatological aspects. Part 1: Pathogenesis, epidemiology, clinical findings”, *JDDG: Journal der Deutschen Dermatologischen Gesellschaft*, v. 10, n. 10, pp. 705–716, 2012.
- [5] TANI, C., BELLANDO, R. S., GUIDUCCI, S., et al. “Systemic sclerosis: a critical digest of the recent literature.” *Clinical and experimental rheumatology*, v. 31, n. 2 Suppl 76, pp. 172–179, 2012.
- [6] LOPES, A. J., CAPONE, D., MOGAMI, R., et al. “Systemic sclerosis-associated interstitial pneumonia: evaluation of pulmonary function over a five-year period”, *Jornal Brasileiro de Pneumologia*, v. 37, n. 2, pp. 144–151, 2011.
- [7] ANTONIOU, K., MARGARITOPOULOS, G., GOH, N., et al. “Combined Pulmonary Fibrosis and Emphysema in Scleroderma-Related Lung Disease Has a Major Confounding Effect on Lung Physiology and Screening for Pulmonary Hypertension”, *Arthritis & Rheumatology*, v. 68, n. 4, pp. 1004–1012, 2016.
- [8] OTSU, N. “A threshold selection method from gray-level histograms”, *IEEE transactions on systems, man, and cybernetics*, v. 9, n. 1, pp. 62–66, 1979.

- [9] VALA, M. H. J., BAXI, A. “A review on Otsu image segmentation algorithm”, *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, v. 2, n. 2, pp. pp-387, 2013.
- [10] KUMAR, S., KUMAR, P., SHARMA, T. K., et al. “Bi-level thresholding using PSO, artificial bee colony and MRLDE embedded with Otsu method”, *Memetic Computing*, v. 5, n. 4, pp. 323–334, 2013.
- [11] YUAN, X.-C., WU, L.-S., PENG, Q. “An improved Otsu method using the weighted object variance for defect detection”, *Applied Surface Science*, v. 349, pp. 472–484, 2015.
- [12] ZHOU, C., TIAN, L., ZHAO, H., et al. “A method of two-dimensional Otsu image threshold segmentation based on improved firefly algorithm”. In: *Cyber Technology in Automation, Control, and Intelligent Systems (CYBER), 2015 IEEE International Conference on*, pp. 1420–1424. IEEE, 2015.
- [13] KUMAR, V., LAL, T., DHULIYA, P., et al. “A study and comparison of different image segmentation algorithms”. In: *Advances in Computing, Communication, & Automation (ICACCA)(Fall), International Conference on*, pp. 1–6. IEEE, 2016.
- [14] ZHANG, Y., YAN, H., ZOU, X., et al. “Image threshold processing based on simulated annealing and OTSU method”. In: *Proceedings of the 2015 Chinese Intelligent Systems Conference*, pp. 223–231. Springer, 2016.
- [15] IM, H.-J., SOLAIYAPPAN, M., BRADSHAW, T., et al. “Validation of Multi-level Otsu Method to Define Metabolic Tumor Volume in Positron Emission Tomography”, *Journal of Nuclear Medicine*, v. 57, n. supplement 2, pp. 1405–1405, 2016.
- [16] RYALAT, M. H., EMMENS, D., HULSE, M., et al. “Evaluation of Particle Swarm Optimisation for Medical Image Segmentation”. In: *International Conference on Systems Science*, pp. 61–72. Springer, 2016.
- [17] UDUPA, J. K., SAHA, P. K. “Fuzzy connectedness and image segmentation”, *Proceedings of the IEEE*, v. 91, n. 10, pp. 1649–1669, 2003.
- [18] SAHA, P. K., UDUPA, J. K., ODHNER, D. “Scale-based fuzzy connected image segmentation: theory, algorithms, and validation”, *Computer Vision and Image Understanding*, v. 77, n. 2, pp. 145–174, 2000.

- [19] PAL, S. K., KING, R. A., HASHIM, A. “Automatic grey level thresholding through index of fuzziness and entropy”, *Pattern Recognition Letters*, v. 1, n. 3, pp. 141–146, 1983.
- [20] PAL, N. R., PAL, S. K. “A review on image segmentation techniques”, *Pattern recognition*, v. 26, n. 9, pp. 1277–1294, 1993.
- [21] PAL, N. R. “On minimum cross-entropy thresholding”, *Pattern Recognition*, v. 29, n. 4, pp. 575–580, 1996.
- [22] KAPUR, J. N., SAHOO, P. K., WONG, A. K. “A new method for gray-level picture thresholding using the entropy of the histogram”, *Computer vision, graphics, and image processing*, v. 29, n. 3, pp. 273–285, 1985.
- [23] WONG, A. K., SAHOO, P. K. “A gray-level threshold selection method based on maximum entropy principle”, *IEEE Transactions on Systems, Man, and Cybernetics*, v. 19, n. 4, pp. 866–871, 1989.
- [24] ZADEH, L. A. “Fuzzy sets”, *Information and control*, v. 8, n. 3, pp. 338–353, 1965.
- [25] LOPES, A. J., CAPONE, D., MOGAMI, R., et al. “Severity classification for idiopathic pulmonary fibrosis by using fuzzy logic”, *Clinics*, v. 66, n. 6, pp. 1015–1019, 2011.
- [26] ANANTHI, V., BALASUBRAMANIAM, P., LIM, C. P. “Segmentation of gray scale image based on intuitionistic fuzzy sets constructed from several membership functions”, *Pattern Recognition*, v. 47, n. 12, pp. 3870–3880, 2014.
- [27] BUSTINCE, H., BARRENECHEA, E., PAGOLA, M. “Image thresholding using restricted equivalence functions and maximizing the measures of similarity”, *Fuzzy Sets and Systems*, v. 158, n. 5, pp. 496–516, 2007.
- [28] PAL, S. K., ROSENFELD, A. “Image enhancement and thresholding by optimization of fuzzy compactness”, *Pattern Recognition Letters*, v. 7, n. 2, pp. 77–86, 1988.
- [29] RAMESH, N., YOO, J.-H., SETHI, I. “Thresholding based on histogram approximation”, *IEE Proceedings-Vision, Image and Signal Processing*, v. 142, n. 5, pp. 271–279, 1995.
- [30] JAWAHAR, C., BISWAS, P. K., RAY, A. “Investigations on fuzzy thresholding based on fuzzy clustering”, *Pattern Recognition*, v. 30, n. 10, pp. 1605–1613, 1997.

- [31] ATANASSOV, K. T. “Intuitionistic fuzzy sets”, *Fuzzy sets and Systems*, v. 20, n. 1, pp. 87–96, 1986.
- [32] MELO-PINTO, P., COUTO, P., BUSTINCE, H., et al. “Image segmentation using Atanassov’s intuitionistic fuzzy sets”, *Expert Systems with Applications*, v. 40, n. 1, pp. 15–26, 2013.
- [33] BALASUBRAMANIAM, P., ANANTHI, V. “Image fusion using intuitionistic fuzzy sets”, *Information Fusion*, v. 20, pp. 21–30, 2014.
- [34] HUANG, C.-W., LIN, K.-P., WU, M.-C., et al. “Intuitionistic fuzzy c-means clustering algorithm with neighborhood attraction in segmenting medical image”, *Soft Computing*, v. 19, n. 2, pp. 459–470, 2015.
- [35] FARNOOSH, R., RAHIMI, M., KUMAR, P. “Removing noise in a digital image using a new entropy method based on intuitionistic fuzzy sets”. In: *Fuzzy Systems (FUZZ-IEEE), 2016 IEEE International Conference on*, pp. 1328–1332. IEEE, 2016.
- [36] CHAIRA, T. “Intuitionistic fuzzy segmentation of medical images”, *IEEE Transactions on Biomedical Engineering*, v. 57, n. 6, pp. 1430–1436, 2010.
- [37] BLAND, J. M., ALTMAN, D. “Statistical methods for assessing agreement between two methods of clinical measurement”, *The lancet*, v. 327, n. 8476, pp. 307–310, 1986.
- [38] WHITE, B. “Interstitial lung disease in scleroderma”, *Rheumatic Disease Clinics of North America*, v. 29, n. 2, pp. 371–390, 2003.
- [39] VAN DEN HOOGEN, F., KHANNA, D., FRANSEN, J., et al. “classification criteria for systemic sclerosis: an American college of”, 2013.
- [40] FREIRE, E. A. M., CICONELLI, R. M., SAMPAIO-BARROS, P. D., et al. “Análise dos critérios diagnósticos, de classificação, atividade e gravidade de doença na esclerose sistêmica”, *Revista Brasileira de Reumatologia*, 2004.
- [41] LEROY, E. C., MEDSGER, T. A. “Criteria for the classification of early systemic sclerosis.” *The Journal of rheumatology*, v. 28, n. 7, pp. 1573–1576, 2001.
- [42] STEEN, V. D., CONTE, C., OWENS, G. R., et al. “Severe restrictive lung disease in systemic sclerosis”, *Arthritis & Rheumatology*, v. 37, n. 9, pp. 1283–1289, 1994.

- [43] SEIBOLD, J., KELLEY, W., HARRIS, E., et al. “Text book of rheumatology”, *Scleroderma, 5th edn. Saunders, Philadelphia*, pp. 1133–1162, 1997.
- [44] SCHURAWITZKI, H., STIGLBAUER, R., GRANINGER, W., et al. “Interstitial lung disease in progressive systemic sclerosis: high-resolution CT versus radiography.” *Radiology*, v. 176, n. 3, pp. 755–759, 1990.
- [45] BLOM-BÜLOW, B., JONSON, B., BRAUER, K. “Lung function in progressive systemic sclerosis is dominated by poorly compliant lungs and stiff airways.” *European journal of respiratory diseases*, v. 66, n. 1, pp. 1–8, 1985.
- [46] PISTELLI, R., MAINI, C. L., FUSO, L., et al. “Pulmonary involvement in progressive systemic sclerosis: a multidisciplinary approach”, *Respiration*, v. 51, n. 4, pp. 296–306, 1987.
- [47] GRIMSDALE, R., SUMNER, F., TUNIS, C., et al. “A system for the automatic recognition of patterns”, *Proceedings of the IEE-Part B: Radio and Electronic Engineering*, v. 106, n. 26, pp. 210–221, 1959.
- [48] ROSENFELD, A. “Connectivity in digital pictures”, *Journal of the ACM (JACM)*, v. 17, n. 1, pp. 146–160, 1970.
- [49] CONCI, A. “AZEVEDO, Eduardo. LETA, Fabiana R”, *Computação Gráfica: Teoria e Prática. Rio de Janeiro: Campus*, v. 407, pp. 2, 2008.
- [50] VELA, J. G., BHAYA, A., MONTEIRO, A. M. V., et al. “Digitalization of X-ray films with image stitching”, *Radiologia Brasileira*, v. 44, n. 4, pp. 233–237, 2011.
- [51] GONZALEZ, R. C., WOODS, R. “Processamento digital de imagens. tradução: Cristina yamagami e leonardo piamonte”. 2010.
- [52] UDUPA, J. K., LEBLANC, V. R., ZHUGE, Y., et al. “A framework for evaluating image segmentation algorithms”, *Computerized Medical Imaging and Graphics*, v. 30, n. 2, pp. 75–87, 2006.
- [53] DOUGHERTY, G. *Digital image processing for medical applications*. Cambridge University Press, 2009.
- [54] FAROOQUE, Y., RAEEN, S. “Latest Trends On Image Segmentation Schemes”, *International Journal Of Advanced Research In Computer Science And Software Enginnering*, v. 4, n. 10, pp. 792–797, 2014.
- [55] ZADEH, L. A. “Fuzzy logic”, *Computer*, v. 21, n. 4, pp. 83–93, 1988.

- [56] FUKUNAGA, K. *Introduction to statistical pattern recognition*. Academic press, 2013.
- [57] VLACHOS, I. K., SERGIADIS, G. D. “Intuitionistic fuzzy information—applications to pattern recognition”, *Pattern Recognition Letters*, v. 28, n. 2, pp. 197–206, 2007.
- [58] PAL, S. K., KING, R. A. “Image enhancement using fuzzy set”, *Electronics letters*, v. 16, n. 10, pp. 376–378, 1980.
- [59] PAL, S. K., KING, R., OTHERS. “Image enhancement using smoothing with fuzzy sets”, *IEEE TRANS. SYS., MAN, AND CYBER.*, v. 11, n. 7, pp. 494–500, 1981.
- [60] PAL, S. K. “A note on the quantitative measure of image enhancement through fuzziness”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, , n. 2, pp. 204–208, 1982.
- [61] ZIMMERMANN, H.-J. *Fuzzy set theory—and its applications*. Springer Science & Business Media, 2011.
- [62] CHAIRA, T., RAY, A. K. “Segmentation using fuzzy divergence”, *Pattern Recognition Letters*, v. 24, n. 12, pp. 1837–1844, 2003.
- [63] ATANASSOV, K. T. “Intuitionistic fuzzy sets”. In: *Intuitionistic fuzzy sets*, Springer, pp. 1–137, 1999.
- [64] DE LUCA, A., TERMINI, S. “A definition of a nonprobabilistic entropy in the setting of fuzzy sets theory”, *Information and control*, v. 20, n. 4, pp. 301–312, 1972.
- [65] ZADEH, L. A. “Outline of a new approach to the analysis of complex systems and decision processes”, *IEEE Trans. Syst. Man Cybern.*, v. 3, pp. 28–44, 1973.
- [66] ZADEH, L. A. “The birth and evolution of fuzzy logic”, *International Journal Of General System*, v. 17, n. 2-3, pp. 95–105, 1990.
- [67] MAMDANI, E. H. “Application of fuzzy algorithms for control of simple dynamic plant”. In: *Proceedings of the Institution of Electrical Engineers*, v. 121, pp. 1585–1588. IET, 1974.
- [68] GOMIDE, F., GUDWIN, R. R., TANSCHHEIT, R. “Conceitos fundamentais da teoria de conjuntos fuzzy, lógica fuzzy e aplicações”. In: *Proc. 6 th IFSA Congress-Tutorials*, pp. 1–38, 1995.

- [69] BOURGANI, E., STYLIOS, C. D., MANIS, G., et al. “Time dependent fuzzy cognitive maps for medical diagnosis”. In: *Hellenic Conference on Artificial Intelligence*, pp. 544–554. Springer, 2014.
- [70] WARSZAWSKI, S., NETZER, R., TAWFIK, D. S., et al. “A “fuzzy”-logic language for encoding multiple physical traits in biomolecules”, *Journal of molecular biology*, v. 426, n. 24, pp. 4125–4138, 2014.
- [71] KUMAR, J. D., MOHAN, V. “Edge Detection in the medical MR brain image based on fuzzy logic technique”. In: *Information Communication and Embedded Systems (ICICES), 2014 International Conference on*, pp. 1–9. IEEE, 2014.
- [72] FARAHANI, F. V., ZARANDI, M. F., AHMADI, A. “Fuzzy rule based expert system for diagnosis of lung cancer”. In: *Fuzzy Information Processing Society (NAFIPS) held jointly with 2015 5th World Conference on Soft Computing (WConSC), 2015 Annual Conference of the North American*, pp. 1–6. IEEE, 2015.
- [73] GHOSH, S., KUNDU, D., PAUL, G. “A Fuzzy Logic Approach in Emotion Detection and Recognition and Formulation of an Odor-Based Emotional Fitness Assistive System”, *International Journal of Synthetic Emotions (IJSE)*, v. 6, n. 2, pp. 14–34, 2015.
- [74] SRIDHAR, B., REDDY, K., PRASAD, A. M. “Mammographic image analysis based on adaptive morphological fuzzy logic CAD system”, *International Journal of Biomedical Engineering and Technology*, v. 17, n. 4, pp. 341–355, 2015.
- [75] JAVED, U., RIAZ, M. M., GHAFLOOR, A., et al. “SAR image segmentation based on active contours with fuzzy logic”, *IEEE Transactions on Aerospace and Electronic Systems*, v. 52, n. 1, pp. 181–188, 2016.
- [76] BARKANA, B. D., SARICICEK, I., YILDIRIM, B. “Performance analysis of descriptive statistical features in retinal vessel segmentation via fuzzy logic, ANN, SVM, and classifier fusion”, *Knowledge-Based Systems*, v. 118, pp. 165–176, 2017.
- [77] RUBIO, Y., MONTIEL, O., SEPÚLVEDA, R. “Microcalcification Detection in Mammograms Based on Fuzzy Logic and Cellular Automata”. In: *Nature-Inspired Design of Hybrid Intelligent Systems*, Springer, pp. 583–602, 2017.

- [78] KAUR, M., RATTAN, M., SINGH, P. “Automatic Segmenting Structures in MRI’s Based on Texture Analysis and Fuzzy Logic”, *Sensing and Imaging*, v. 18, n. 1, pp. 2, 2017.
- [79] YAGER, R. R. “On the measure of fuzziness and negation part I: membership in the unit interval”, 1979.
- [80] YAGER, R. R. “On ordered weighted averaging aggregation operators in multicriteria decisionmaking”, *IEEE Transactions on systems, Man, and Cybernetics*, v. 18, n. 1, pp. 183–190, 1988.
- [81] MORETTIN, P., BUSSAB, W. “Estatística Básica. Saraiva”. 2013.
- [82] HIRAKATA, V. N., CAMEY, S. A. “Análise de concordância entre métodos de Bland-Altman”, *Revista HCPA. Porto Alegre. Vol. 29, no. 3 (2009), p. 261-268.*, 2009.
- [83] MCCONNELL, D., JORDAN, L., KEMP, B., et al. “Clinical Evaluation of Two Modeling Programs in Assessing Neurodegenerative Disease in 18F-FDG PET Imaging.” *Journal of Nuclear Medicine*, v. 57, n. supplement 2, pp. 2640–2640, 2016.
- [84] GÓMEZ-POLO, C., MUÑOZ, M. P., LUENGO, M. C. L., et al. “Comparison of two color-difference formulas using the Bland-Altman approach based on natural tooth color space”, *The Journal of prosthetic dentistry*, v. 115, n. 4, pp. 482–488, 2016.
- [85] TEIXEIRA, P. A. G., FORMERY, A.-S., HOSSU, G., et al. “Evidence-based recommendations for musculoskeletal kinematic 4D-CT studies using wide area-detector scanners: a phantom study with cadaveric correlation”, *European radiology*, v. 27, n. 2, pp. 437–446, 2017.