Sistematização da percepção médica na
construção de sistemas para recuperação de
imagens por conteúdo

Marcelo Ponciano da Silva

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Sistematização da percepção médica na construção de sistemas para recuperação de imagens por conteúdo¹

Marcelo Ponciano da Silva

Orientador: *Profa. Dra. Agma Juci Machado Traina*

Tese apresentada ao Instituto de Ciências Matemáticas e de Computação - ICMC-USP, como parte dos requisitos para obtenção do título de Doutor em Ciências - Ciências de Computação e Matemática Computacional. VERSÃO REVISADA.

USP – São Carlos
Abril de 2014

¹ Este trabalho teve apoio financeiro do CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), processo 141535/2009-1

Ficha catalográfica preparada pela Seção de Tratamento
da Informação da Biblioteca Prof. Achille Bassi – ICMC/USP

S586s Silva, Marcelo Ponciano da
Sistematização da percepção médica na construção de
sistemas para recuperação de imagens por conteúdo /
Marcelo Ponciano da Silva ; orientadora Agma Juci Machado
Traina. -- São Carlos, 2014.
125 p.

Tese (Doutorado - Programa de Pós-Graduação em
Ciências de Computação e Matemática Computacional)-
Instituto de Ciências Matemáticas e de Computação,
Universidade de São Paulo, 2014.

1. Recuperação de imagens por conteúdo. 2. CBIR. 3.
Algoritmos de extração de características de imagens. 4.
Imagens médicas. 5. Apoio ao diagnóstico por imagens. I.
Traina, Agma Juci Machado, orient. II. Título.

*Para minha esposa,
meus filhos
e meus queridos pais*

AGRADECIMENTOS

Primeiramente a Deus, meu criador e provedor de toda fonte de vida e inteligência.

À minha amada esposa, tão dedicada e amorosa, por ser meu porto seguro, meu apoio e minha fonte de energia incondicional.

Aos meus filhos Ester, Pedro e Arthur, pelos momentos de brincadeiras e descontração, que sempre me ajudaram a relaxar e renovar meus ânimos.

Aos meus estimados pais e meus queridos sogro e sogra, que tanto me apoiam e incentivam.

À minha orientadora, pela confiança, dando-me apoio, conselhos e incentivos, sempre demonstrando um carinho e preocupação de mãe pelo meu bem estar e sucesso.

Aos professores, Prof. Dr. Paulo Mazzoncini de A. Marques e Prof. Dr. Marcello Henrique Nogueira-Barbosa, pela amizade, incentivo e por permitir a realização da parte prática desse trabalho, dando-me acesso ao HCFMRP – USP e ao CCIFM. Aos residentes e amigos do CCIFM, Juliana Souza e Rafael Menezes Reis, pela preciosa ajuda na parte da aplicação médica desse trabalho.

Aos amigos do GBDI, especialmente ao Pedro Henrique Bugatti, Marcos Vinícius Naves Bedo, Willian Dener e Daniel dos Santos Kaster, por sempre estarem dispostos a me ajudarem e colaborarem com o trabalho.

Ao CNPq pelo apoio financeiro na pesquisa.

RESUMO

Nos últimos anos o mundo tem vivenciado uma avalanche de novas tecnologias para auxílio ao diagnóstico médico. Esses esforços buscam um diagnóstico rápido e preciso através de exames e informações sobre a condição física do paciente. Através do uso de imagens médicas, a radiologia busca a visualização de órgãos ou estruturas internas do corpo humano para encontrar respostas às suspeitas de problemas físicos expressos por sinais e sintomas relatados pelo paciente. Nessa área, os Sistemas de Comunicação e Armazenamento de Imagens (PACS) têm ajudado no armazenamento e organização do crescente número de imagens geradas pelos exames realizados nos hospitais. Trabalhos de pesquisa médica têm evidenciado o potencial de uso dessas imagens como auxílio à prática da Medicina Baseada em Casos Similares (MBCS). Por esse motivo, há na literatura um esforço contínuo em desenvolver técnicas computacionais para recuperação de imagens baseada em conteúdos similares (CBIR) em grandes conjuntos de dados. As consultas por similaridade são essenciais para apoiar a prática da MBCS e a descoberta de comportamentos de lesões causadas por diversas doenças. A evolução e intensificação das pesquisas em CBIR têm encontrado vários desafios. Um desses é a divergência entre os resultados obtidos automaticamente e aqueles esperados pelos radiologistas (descontinuidade semântica). Outro desafio é a falta de estudos sobre a viabilidade clínica dessas ferramentas como forma de auxílio ao diagnóstico. Esses obstáculos são dois dos principais responsáveis pela não efetivação dessa tecnologia no ambiente médico-hospitalar. Mediante o exposto acima, este trabalho de pesquisa propõe um mecanismo para contornar essa descontinuidade semântica e ao mesmo tempo aproximar o CBIR do ambiente real de aplicação.

A contribuição principal deste trabalho foi o desenvolvimento de uma metodologia baseada em parâmetros perceptuais que aproximam o sistema ao nível de percepção do usuário médico. Em seguida, foi realizado um estudo sobre a viabilidade clínica do sistema CBIR no Hospital das Clínicas de Ribeirão Preto. A metodologia proposta foi aplicada e os resultados comprovaram a aplicabilidade de Sistemas CBIR como ferramenta de auxílio ao diagnóstico em um ambiente clínico real.

ABSTRACT

In recent years the world has experienced an avalanche of new technologies to aid medical diagnosis. These efforts seek a quick and accurate diagnosis through exams and information about the patient's physical condition. The radiology studies the visualization of the organs or structures through the use of images. In this area, the Picture Archiving and Communication Systems (PACS) have helped in the storage and organization of the growing number of images generated by exams performed in hospitals. Medical research papers have shown the potential use of these images as an aid to the Similar Case-Based Reasoning (SCBR) practice in Medicine. For this reason, there is an ongoing effort in the literature to develop computational techniques for Content-Based Image Retrieval (CBIR) in large data sets. Similarity queries are essential to support the practice of SCBR. The evolution and intensification of research in CBIR have encountered several challenges. One of these is the discrepancy between the results obtained automatically and those expected by radiologists (semantic gap). Another challenge is the lack of studies on the clinical viability of these tools as a way to assist in diagnosis. These obstacles are the two main responsible for reservation in using this technology in the medical hospital environment. Considering this scenario, this research proposes a mechanism to overcome this semantic gap and bring the real environment to the CBIR application. The main contribution for this research was the development of a methodology based on Perceptual Parameters to approximate the system to the level of user perception. Then we conducted a study on the clinical viability of a CBIR system at the Clinical Hospital of the University of São Paulo at Ribeirão Preto. The proposed methodology was applied and the results showed the applicability of CBIR systems as a computer aided diagnosis tool in a real clinical environment.

SUMÁRIO

AGRADECIMENTOS	VII
RESUMO	II
ABSTRACT	IV
SUMÁRIO	VI
LISTA DE FIGURAS	VIII
LISTA DE TABELAS	X
LISTA DE ABREVIATURAS E SIGLAS	XII
CAPÍTULO 1 - INTRODUÇÃO	1
1.1 CONSIDERAÇÕES INICIAIS	1
1.2 MOTIVAÇÃO.....	3
1.3 OBJETIVOS	4
1.4 ORGANIZAÇÃO.....	5
CAPÍTULO 2 - PROCESSAMENTO DE IMAGENS MÉDICAS PARA AUXÍLIO AO DIAGNÓSTICO	7
2.1 CONSIDERAÇÕES INICIAIS	7
2.2 PROCESSAMENTO, ANÁLISE E RECONHECIMENTO DE PADRÕES EM IMAGENS MÉDICAS	8
2.2.1 <i>Processamento da Imagem</i>	9
2.2.2 <i>Detecção de Características</i>	10
2.2.3 <i>Segmentação de Estruturas</i>	15
2.2.4 <i>Reconhecimento das Características</i>	18
2.3 SISTEMAS DE DIAGNÓSTICO AUXILIADO POR COMPUTADOR (CAD)	19
2.3.1 <i>Auxílio à Detecção de Lesões</i>	20
2.3.2 <i>Auxílio à classificação diagnóstica</i>	20
2.3.3 <i>Desempenho dos Sistemas CAD</i>	21
2.4 CONSIDERAÇÕES FINAIS.....	23
CAPÍTULO 3 - RECUPERAÇÃO DE IMAGENS BASEADA EM CONTEÚDO.....	25
3.1 CONSIDERAÇÕES INICIAIS	25
3.2 REPRESENTAÇÃO DO CONTEÚDO INTRÍNSECO À IMAGEM	26
3.3 CONSULTAS POR SIMILARIDADE: DEFINIÇÃO, SUPORTE E ESTRUTURAS DE INDEXAÇÃO PARA DADOS MÉTRICOS	29
3.4 SISTEMAS CBIR: ESTADO DA ARTE E DESAFIOS.....	31
<i>Sistema Higii</i>	34
<i>Desafios em CBIR</i>	35
<i>Avaliação de Sistemas CBIR com o usuário</i>	36
3.5 TÉCNICAS PARA DIMINUIR A DESCONTINUIDADE SEMÂNTICA (<i>SEMANTIC GAP</i>)	37
<i>Explorando o espaço perceptual</i>	37
<i>Ontologia</i>	38
<i>Realimentação Por Relevância</i>	39
<i>Recuperação por Texto e Conteúdo</i>	41
3.6 MÉTODOS DE AVALIAÇÃO	41
3.7 CONSIDERAÇÕES FINAIS.....	44
CAPÍTULO 4 - PERCEPÇÃO DO ESPECIALISTA PARA CONSULTAS POR SIMILARIDADE EM IMAGENS MÉDICAS	45
4.1 CONSIDERAÇÕES INICIAIS	45
4.2 CONCEITOS DE SIMILARIDADE PARA RECUPERAÇÃO DE IMAGENS POR CONTEÚDO	45
4.3 PROCESSO DE ANÁLISE HUMANA NO DIAGNÓSTICO POR IMAGEM (SEMILOGIA RADIOLÓGICA).....	47
4.4 ESTABELECIMENTO DE DOMÍNIOS ESPECÍFICOS	49
4.4.1 <i>Massa e Calcificação em Regiões de Interesse de Mamografias</i>	50
4.4.2 <i>Lesões Pulmonares Difusas em CT de Tórax</i>	51

4.4.3 Lesões por Compressão Vertebral em Imagens de RM da Coluna	52
4.5 CONSIDERAÇÕES FINAIS.....	53
CAPÍTULO 5 – SISTEMATIZAÇÃO DA PERCEPÇÃO MÉDICA NA CONSTRUÇÃO DE SISTEMAS CBIR	55
5.1 CONSIDERAÇÕES INICIAIS	55
5.2 REPRESENTAÇÃO DE CONTEÚDO INTRÍNSECO EM IMAGENS MÉDICAS	56
5.2.1 Proposta de Hierarquização de Extratores de Características	56
5.2.2 Discussão sobre a adequação da proposta	58
5.3 DEFINIÇÃO DE “CRITÉRIOS DE SIMILARIDADE” PARA COMPARAÇÃO DE IMAGENS MÉDICAS	59
5.3.1 Proposta de Hierarquização de Critérios de Similaridade para Imagens Médicas	60
5.3.2 Formalização dos Critérios de Similaridade.....	61
5.3.3 Definição do melhor descritor de similaridade para cada parâmetro de percepção	65
5.3.4 Estudo de Caso Prático: Imagens de Mama	66
5.3.5 Estudo de Caso Teórico: Definição de Vários Contextos	68
5.3.5 Discussão.....	70
5.4 IDENTIFICAÇÃO AUTOMÁTICA DE CRITÉRIOS DE SIMILARIDADE.....	71
5.4.1 Definição automática de Contextos de Análise	71
5.4.2 Identificação automática de Parâmetros de Percepção.....	74
5.5 EXPERIMENTOS EM AMBIENTE REAL	75
5.5.1 Materiais e Métodos	76
5.5.2 Resultados	77
5.6 CONSIDERAÇÕES FINAIS.....	78
CAPÍTULO 6 –REPRESENTAÇÃO DE IMAGENS DE COLUNA VERTEBRAL PARA CBIR PERCEPTUAL.....	81
6.1 CONSIDERAÇÕES INICIAIS	81
6.2 METODOLOGIA PROPOSTA	81
6.2.1 Representação das Imagens de Coluna para CBIR Perceptual	82
6.2.2 Extração de Características Baseada em Análise da Coluna	84
6.3 EXPERIMENTOS.....	86
6.3.1 Materiais e Métodos	86
6.3.2 Resultados	87
6.4 CONSIDERAÇÕES FINAIS.....	89
CAPÍTULO 7 – AVALIAÇÃO DA VIABILIDADE CLÍNICA DE UM CBIR EM AMBIENTE REAL	91
7.1 CONSIDERAÇÕES INICIAIS	91
7.2 METODOLOGIA PROPOSTA	92
7.3 EXPERIMENTOS.....	93
7.3.1 Materiais e Métodos	93
7.3.2 Resultados	95
7.3.3 Trabalho Colaborativo: Medida de Satisfação e usabilidade	98
7.4 CONSIDERAÇÕES FINAIS.....	99
CAPÍTULO 8 - CONCLUSÃO	101
8.1 CONSIDERAÇÕES FINAIS.....	101
8.2 PRINCIPAIS CONTRIBUIÇÕES.....	103
8.3 PUBLICAÇÕES GERADAS.....	104
8.4 PROPOSTAS PARA TRABALHOS FUTUROS	105
REFERÊNCIAS	107

LISTA DE FIGURAS

FIGURA 1: PIPELINE BÁSICO DE PIM PARA AUXÍLIO AO DIAGNÓSTICO	8
FIGURA 2: GRÁFICO DA FUNÇÃO DE JANELAMENTO (<i>WINDOWING</i>)	10
FIGURA 3: APLICAÇÃO DA FUNÇÃO DE JANELAMENTO EM IMAGENS MÉDICAS	10
FIGURA 4: REPRESENTAÇÃO DE COR DE UMA (A) IMAGEM ATRAVÉS DE UM: (B) HISTOGRAMA TRADICIONAL, (C).HISTOGRAMA MÉTRICO	12
FIGURA 5: REPRESENTAÇÃO DE TEXTURA POR MATRIZ DE CO-OCORRÊNCIA	13
FIGURA 6: (A) IMAGEM ORIGINAL; (B) IMAGEM SEGMENTADA; (C) REGIÃO DE FLÚIDO CÉREBRO-ESPINHAL; (D) REGIÃO DE MASSA CINZENTA; (E) REGIÃO DE MASSA BRANCA; (F) REGIÃO DA MEDULA ÓSSEA E GORDURA.....	15
FIGURA 7: EXEMPLO DE UMA (A) IMAGEM DE RESSONÂNCIA E SUA (C) SEGMENTAÇÃO BASEADA NA (B) IDENTIFICAÇÃO DE LIMAR BASEADO NA TÉCNICA DE OTSU	16
FIGURA 8: (A) IMAGEM DE RM ORIGINAL. RESULTADO DA APLICAÇÃO DOS OPERADORES DE SOBEL PARA OBTENÇÃO DE (B) GX, (C) GY E DA (D) IMAGEM GRADIENTE COMPLETA	17
FIGURA 9: (A) IMAGEM DE CT DE PULMÃO; (B) APLICAÇÃO DE CRESCIMENTO DE REGIÃO PARA SEGMENTAÇÃO DO PULMÃO ESQUERDO.....	17
FIGURA 10: EXEMPLO DE CURVA ROC	23
FIGURA 11: VISÃO GERAL DE UM SISTEMA CBIR PARA IMAGENS MÉDICAS	25
FIGURA 12: PROCESSOS ONDE ATUA O USO DE TÉCNICAS DE REALIMENTAÇÃO POR RELEVÂNCIA	39
FIGURA 13: ILUSTRAÇÃO: EXEMPLO DE DISTRIBUIÇÃO DE CONJUNTOS DE IMAGENS PARA CÁLCULO DE PRECISÃO VS. REVOCAÇÃO	42
FIGURA 14: EXEMPLO DE GRÁFICO DE PRECISÃO VS. REVOCAÇÃO	43
FIGURA 15: EXEMPLO DA NÃO TRANSITIVIDADE EM COMPARAÇÃO DE IMAGENS (FELIPE 2005).....	46
FIGURA 16: VARIAÇÕES DE FORMAS E CONTORNOS EM NÓDULOS DE MAMA	50
FIGURA 17: VISÃO GERAL EM NÍVEIS PARA DEFINIÇÃO DE CRITÉRIOS SIMILARIDADE EM IMAGENS MÉDICAS	60
FIGURA 18: MODELO DE DADOS PARA SUPORTAR DEFINIÇÃO AUTOMÁTICA DE CRITÉRIOS DE SIMILARIDADE	73
FIGURA 19: EXEMPLO DE ARQUIVO XML PARA ESPECIFICAÇÃO DE REQUISITOS DE CONTEXTO/DESCRITORES/PARÂMETROS DE PERCEPÇÃO	74
FIGURA 20: EXEMPLO DE TELA DO SISTEMA HIGIA	77
FIGURA 21: RESULTADO DA ESCOLHA DOS ESPECIALISTAS PARA CONSULTAS COM E SEM O PARÂMETRO DE PERCEPÇÃO.....	78
FIGURA 22: DIFERENTES MÉTODOS PARA SE COMPARAR IMAGENS MÉDICAS	83
FIGURA 23: CLASSIFICAÇÃO DOS PIXELS ENTRE BORDA (PIXEL CINZA) E INTERIOR (PIXEL BRANCO) UTILIZANDO O ALGORITMO A) BIC TRADICIONAL E O B) BIC-MED.	84
FIGURA 24: REPRESENTAÇÃO DA FORMA DO CORPO VERTEBRAL.....	86
FIGURA 25: DESEMPENHO DE DIFERENTES MÉTODOS PARA SE COMPARAR IMAGENS DE COLUNA.....	88
FIGURA 26: DIFERENTES MÉTODOS PARA SE COMPARAR IMAGENS MÉDICAS	89

FIGURA 27: METODOLOGIA PROPOSTA PARA AVALIAÇÃO DE VIABILIDADE CLÍNICA EM SISTEMAS CBIR	93
FIGURA 28: EXEMPLO DE IMAGENS DA BASE DE MAMA	94
FIGURA 29: COMPARAÇÃO ENTRE PRECISÃO DO MÉDICO E DO SISTEMA EM CLASSIFICAR AS IMAGENS.....	96
FIGURA 30: VARIAÇÃO DO “GRAU DE CERTEZA” DOS MÉDICOS DURANTE UTILIZAÇÃO DO SISTEMA.	97
FIGURA 31: VISÃO GERAL DE UM SISTEMA CBIR PERCEPTUAL	102

LISTA DE TABELAS

TABELA 1: RESUMO DAS PRINCIPAIS TÉCNICAS DE LIMIAZIZAÇÃO DE IMAGENS.....	16
TABELA 2: CONCEITOS DE SENSIBILIDADE E ESPECIFICIDADE.....	22
TABELA 3: PRINCIPAIS MEDIDAS/FUNÇÕES DE DISTÂNCIA	31
TABELA 4: ALGUNS DOS SISTEMAS CBIR PARA ÁREA MÉDICA E SUAS ESPECIALIDADES.....	33
TABELA 5: DESCRIÇÃO RESUMIDA DAS PRINCIPAIS TÉCNICAS DE REALIMENTAÇÃO POR RELEVÂNCIA	40
TABELA 6: DESCRIÇÃO RESUMIDA DOS PRINCIPAIS EXAMES RADIOLÓGICOS.....	48
TABELA 7: ALGUMAS TERMINOLOGIAS UTILIZADAS EM EXAMES DE RX E CT	48
TABELA 8: EXEMPLOS DE ACHADOS EM MAMOGRAFIA	50
TABELA 9: EXEMPLOS DE ACHADOS EM CT DE PULMÃO	51
TABELA 10: EXEMPLOS DE ACHADOS EM CT DE PULMÃO	52
TABELA 11: DESCRIÇÃO RESUMIDA DA HIERARQUIA PROPOSTA PARA REPRESENTAÇÃO DE CONTEÚDO VISUAL EM IMAGENS MÉDICAS	58
TABELA 12: PRECISÃO MÉDIA PARA CADA PARÂMETRO DE PERCEPÇÃO	67
TABELA 13: PRECISÃO MÉDIA DA BASE TODA (SEM PARÂMETRO DE PERCEPÇÃO).....	67
TABELA 14: COMPARAÇÃO DE RESULTADOS.....	68
TABELA 15: PRECISÃO DO MÉDICO DURANTE CLASSIFICAÇÃO E PRECISÃO DO SISTEMA CBIR (ÁREA ABAIXO DA CURVA DE PRECISÃO E REVOCAÇÃO).....	95

LISTA DE ABREVIATURAS E SIGLAS

CAD - Computer Aided Diagnosis

CCIFM - Centro de Ciências das Imagens e Física Médica do Hospital das Clínicas de
Ribeirão Preto – USP

CBIR - Content-based Image Retrieval

CBMIR – Content-Based Medical Image Retrieval

CT - Tomografia Computadorizada

DBM - Density-Based Metric Tree

DF-Tree - Distance Fields Tree

EM - Expectation and Maximization

GBdI - Grupo de Bases de Dados e Imagens - ICMC - USP

HC-FMRP - Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto - USP

ICMC-USP - Instituto de Ciências Matemáticas e de Computação - USP.

MAM – Métodos de Acesso Métrico

MBCS – Medicina Baseada em Casos Similares

PACS - Picture Archiving and Communication System

PIM – Processamento de Imagens Médicas

RIS – Radiological Information Systems

RM – Ressonância Magnética

ROI – Region Of Interest (Região de Interesse)

RX – Raio-X

VCF – Vertebral Compression Fractures

Capítulo 1 - Introdução

1.1 Considerações Iniciais

O desenvolvimento de novas tecnologias para a área médica tem crescido muito nos últimos anos. A descoberta do raio-X e a geração de imagens radiológicas, exames de laboratório e provas funcionais, causaram um grande impacto na detecção e descoberta de doenças e suas implicações no corpo humano, proporcionando uma grande contribuição para a área médica como forma de auxílio ao diagnóstico. Hipócrates foi a primeira pessoa que se tem conhecimento a utilizar a palavra “diagnóstico”. Sua definição para essa palavra fazia referência a seu prefixo *dia* (através de), somado ao sufixo *gnosis* (conhecimento). Portanto, "Discernir pelo Conhecimento". O uso do diagnóstico por imagem tem não só facilitado a descoberta de conhecimento sobre as diferentes lesões, mas também agilizado o diagnóstico clínico e a descoberta precoce das doenças através do estudo de suas manifestações. A análise e descoberta de padrões nessas imagens tem se tornado uma ferramenta amplamente eficaz no auxílio ao diagnóstico, ajudando o discernimento médico a tornar-se cada vez mais embasado e seguro.

Seguindo essa linha de pensamento, da disponibilização da informação para ajudar o médico a embasar seu conhecimento, um dos desafios mais evidentes nos últimos anos é a manipulação eficiente da enorme quantidade de informação que vem sendo gerada nos hospitais e centros médicos. Na área médica, os sistemas de informação têm sido desenvolvidos com o objetivo de disponibilizar a informação necessária ao médico de modo rápido e preciso visando assim melhorar a qualidade do cuidado à saúde. Nesse contexto, pode-se citar os Sistemas de Informação Hospitalar (*Hospital Information Systems - HIS*) (Müller et al. 2008), que armazenam informações a respeito do paciente, seu estado de saúde e procedimentos médicos adotados. Há também os Sistemas de Informação em Radiologia (*Radiology Information Systems – RIS*), que armazenam informações referentes aos exames radiológicos (pedidos e suas justificativas) e aos laudos associados (Morioka et al. 2005). Ainda na radiologia, os Sistemas de Comunicação e Armazenamento de Imagens (*Picture Archiving and Communication Systems – PACS*) têm proporcionado um avanço no armazenamento e organização das imagens geradas nos hospitais (Gutierrez 2011). Aliado a esses sistemas, as pesquisas existentes sobre a aplicação de técnicas de CBIR (*Content-Based Image Retrieval*) incorporadas aos PACS vem proporcionando um avanço na recuperação de imagens

armazenadas, antes vinculadas a um identificador do paciente ou de um exame (Valente et al. 2013)(Furuie et al. 2007). Com essa nova abordagem essas buscas passam a ser realizadas por meio de comparações entre imagens (Welter et al. 2012)(Müller et al. 2004)(Zhang & Lu 2002), possibilitando efetuar buscas por similaridade e abrindo novos caminhos para utilização do computador e das imagens médicas em atividades de auxílio ao diagnóstico (Ribeiro et al. 2009)(Aman et al. 2009). A função de recuperação de dados baseada em seu conteúdo é um dos pontos altos que atualmente se deseja incorporar nos sistemas PACS através da criação de uma infraestrutura voltada para a Informática de Imagens Médicas (*Medical Imaging Informatics Infrastructure - MIII*) (Welter et al. 2010)(Fischer, Sauren, et al. 2008).

A abordagem CBIR trabalha com descrições baseadas nas propriedades inerentes das imagens, tais como cor, textura e forma. Contudo, apesar de todos os esforços nas pesquisas, a precisão da recuperação dos algoritmos atuais de CBIR é ainda limitada. Além de outras dificuldades, o gargalo principal é a descontinuidade existente entre as características de baixo nível possíveis de serem extraídas das imagens e os seus conteúdos semânticos associados (Deserno et al. 2009)(Datta et al. 2008). Esse problema, conhecido como descontinuidade semântica (*semantic gap*) origina-se do fato que medidas de similaridade e extratores de características das imagens, tais como histogramas de níveis de cinza, descritores de textura e formas, em geral não possuem correlação direta com semânticas da subjetividade humana (Deserno et al. 2009)(Antani et al. 2008). Para minimizar esse problema semântico, técnicas interativas de avaliação e realimentação de relevância têm sido investigadas já há algum tempo (Smeulders et al. 2000)(Rosa et al. 2002), porém há muito ainda a se explorar nessa linha.

A inclusão de uma função de recuperação de imagens por conteúdo em um ambiente integrado HIS/RIS/PACS poderia trazer contribuições significativas ao processo diagnóstico, através da recuperação rápida e eficiente de imagens representativas de diferentes exames, bem como de suas informações associadas (van de Wetering & Batenburg 2009)(Fischer, Sauren, et al. 2008)(Azevedo-Marques et al. 2008). A proposta deste trabalho consiste em promover a aproximação dos sistemas CBIR à realidade médica e explorar a capacidade desses sistemas como Sistemas de Auxílio ao Diagnóstico (*Computer Aided Diagnosis - CAD*). A ideia principal é desenvolver um mecanismo automático de otimização de consulta por similaridade baseado em parâmetros de percepção levantados pelos próprios radiologistas. Esse método fará uma escolha automática de quais parâmetros perceptuais e possíveis critérios de similaridade deverão ser considerados relevantes no processamento da consulta de determinado tipo de imagem. Esses parâmetros e critérios são definidos automaticamente, através:

- de mineração de palavras-chave nas justificativas do pedido de exame,
- dos dados contidos no cabeçalho DICOM das imagens sob processamento e
- do reconhecimento de padrões na imagem.

Essa abordagem atua como uma “realimentação por relevância à priori”, ou melhor, uma definição automática de contexto, onde as informações do contexto são mineradas a partir do cabeçalho DICOM e as informações da percepção serão deduzidas a partir de palavras-chave contidas nas justificativas do pedido de exame. Assim o sistema poderá aumentar a especificidade dos resultados antes da consulta sequer ser apresentada ao usuário.

Outro ponto importante do trabalho é a validação dos métodos propostos e do sistema CBIR desenvolvido. Nessa etapa realizou-se um estudo sobre o desempenho e a viabilidade desses sistemas como ferramentas de auxílio ao diagnóstico em ambientes reais de diagnóstico por imagem.

O trabalho de pesquisa aqui apresentado buscou suprir a descontinuidade semântica, propondo uma sistematização que aproxima o sistema CBIR ao nível de percepção do usuário médico, investigando e demonstrando sua aplicabilidade como ferramenta de auxílio ao diagnóstico em um ambiente clínico real. Como o sistema proposto foi desenvolvido em um hospital-escola (Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto – HC-FMRP), em trabalhos futuros, a utilização de um sistema CBIR também poderá ser avaliada como ferramenta de ensino médico e suporte ao trabalho didático envolvendo estudos de casos similares contendo imagens associadas.

1.2 Motivação

Vários trabalhos de pesquisa nos últimos anos têm evidenciado o potencial de uso de imagens similares como ferramenta de auxílio à tomada de decisão no processo diagnóstico (Kumar et al. 2013)(Kalpathy-Cramer & Hersh 2010)(Rahman et al. 2010). Porém, a maior parte desses trabalhos está focada em domínios bastante específicos de conhecimento, além de estarem trabalhando com um número reduzido de exames, dificultando a execução de uma avaliação realística da viabilidade desses sistemas CBIR como ferramenta de auxílio ao diagnóstico em um ambiente clínico real (Doi 2006).

Ao longo dos anos as pesquisas em CBIR têm encontrado grandes desafios e desvendado novas fronteiras. Contudo, obstáculos como a divergência entre os resultados obtidos automaticamente pelo sistema e aqueles esperados pelos radiologistas (*semantic gap*) e dificuldades como a falta de estudos sobre a viabilidade clínica dessas ferramentas como

forma de auxílio ao diagnóstico, ainda persistem e são os principais responsáveis pela não efetivação dessa tecnologia no ambiente médico-hospitalar (Deserno et al. 2009). Uma alternativa que vem trazendo novas esperanças ao desenvolvimento desses sistemas é a tentativa de captar a noção de percepção do radiologista durante a consulta por similaridade e a etapa final opcional de *Realimentação por Relevância* (*Relevance Feedback – RF*) (Traina et al. 2009). Sistemas CBIR precisam adquirir uma perspectiva centrada no usuário final para assim alcançar uma larga aceitação nos ambientes reais de diagnóstico por imagem (Jaimes et al. 2006) e esse tem sido o enfoque de pesquisas recentes na área (Ponciano-Silva et al. 2013). A inclusão da percepção médica na construção de ferramentas CBIR, pouco explorada na literatura e proposta neste trabalho, irá aproximar essa tecnologia CBIR do usuário final, quebrando uma barreira clara entre a ciência médica e a ciência da computação.

1.3 Objetivos

Dos objetivos gerais desta pesquisa pode-se ressaltar:

- Diminuir a descontinuidade semântica,
- Desenvolver um mecanismo automático de aprimoramento de consulta por similaridade baseado em critérios de similaridade e parâmetros de percepção levantados pelos próprios radiologistas,
- Desenvolver um Sistema Integrado de Auxílio ao Diagnóstico Médico baseado em consultas por similaridade e
- Realizar uma avaliação da viabilidade clínica de um sistema CBIR em um ambiente real de diagnóstico por imagens.

Os principais objetivos diretos deste trabalho foram:

- Integrar a percepção do especialista do que é similar, nas diversas etapas do processo de recuperação de imagens baseada em seu conteúdo, incluindo parâmetros perceptuais do próprio usuário médico durante os processos de processamento da imagem, extração de características e recuperação por conteúdo,
- Desenvolver técnicas para reconhecimento automático de critérios de similaridade e parâmetros perceptuais relevantes no processo de comparação de imagens e consulta por similaridade,
- Desenvolver um sistema integrado de Auxílio ao Diagnóstico Médico utilizando o resultado do sistema CBIR (aprimorado pelos conceitos de percepção visual do especialista médico) junto aos resultados parciais das etapas de reconhecimento de

padrões nas imagens e reconhecimento de termos em laudo e cabeçalho da imagem para geração de relatórios que apoiam as tomadas de decisões e

- Realizar estudo e validação da viabilidade clínica desse sistema CBIR como ferramenta de auxílio ao diagnóstico por imagem em ambiente real de diagnóstico por imagem, a fim de gerar conhecimentos que indiquem o melhor caminho para a utilização desses sistemas na prática médica.

Para atingir tais objetivos foram utilizadas informações da percepção visual e experiência clínica do médico coletadas durante entrevistas e acompanhamento de sua atuação em situações reais de diagnóstico. Essas informações foram abstraídas para o contexto computacional e incorporadas no processamento das imagens, na extração de características, no processamento de consultas por similaridade (aos k vizinhos mais próximos e por abrangência) e, finalmente, na avaliação da qualidade da resposta do sistema por parte do usuário especialista, com potencial uso da ferramenta para auxílio computadorizado ao diagnóstico (*Computer-aided Diagnosis* - CAD).

1.4 Organização

Nesse capítulo foram apresentadas as considerações iniciais e motivação para o desenvolvimento do trabalho, bem como os objetivos para o seu desenvolvimento. O restante da tese possui a seguinte organização;

- O Capítulo 2 apresenta a teoria e estado da arte envolvendo o processamento de imagens médicas para o auxílio ao diagnóstico. Nele são descritos métodos de processamento, análise e reconhecimento de padrões em imagens médicas, bem como técnicas de utilização do conhecimento extraído das imagens na criação de sistemas de auxílio ao diagnóstico.
- O Capítulo 3 apresenta as etapas de um sistema CBIR. Nele são descritos os processos de extração de características, consultas por similaridade e técnicas para diminuir a descontinuidade semântica. Também são apresentados alguns sistemas CBIR disponíveis na literatura e os desafios encontrados por eles.
- O Capítulo 4 descreve aspectos relacionados à percepção do especialista médico durante a análise e comparação de imagens médicas. Nele são descritos alguns fatores humanos na análise de imagens médicas que foram utilizados na formulação de consultas por similaridade.

- O Capítulo 5 apresenta a proposta chave desse trabalho, mostrando a sistematização da percepção médica para construção de sistemas Perceptual-CBIR. Este capítulo traz a definição bem como a intuição do uso de Critérios de Similaridade e Parâmetros de Percepção no processo de comparação de imagens.
- O Capítulo 6 mostra uma proposta de representação de imagens de Coluna Vertebral para realização de busca por similaridade. Compara os resultados obtidos com a nova técnica com os resultados de técnicas tradicionais, utilizadas na literatura.
- O Capítulo 7 finaliza a contribuição do trabalho apresentando uma avaliação da Viabilidade Clínica de um sistema CBIR em ambiente real. Mostra o comportamento dos radiologistas perante a ferramenta que lhe traz casos similares previamente diagnosticados.
- Finalmente, o Capítulo 8 apresenta as conclusões, publicações geradas até o momento e propostas de trabalhos futuros.

Capítulo 2 - Processamento de Imagens Médicas Para Auxílio ao Diagnóstico

2.1 Considerações Iniciais

O diagnóstico por imagem vem se desenvolvendo de maneira surpreendente nos últimos anos. Após a Radiografia Plana (RX) seguiram-se outros métodos de obtenção de imagens médicas, como por exemplo, a Cintilografia, Ultra-Sonografia, Tomografia Computadorizada (CT), Ressonância Magnética (RM) e, Tomografia com Emissão de Pósitrons e Gamagrafia. Cada um desses exames abrange um objetivo específico de auxílio e, por isso, o médico, ao solicitar um exame radiológico deve saber qual tipo e protocolo de aquisição das imagens melhor revelará as evidências que confirmem (ou eliminem) a(s) suspeita(s) que ele tem sobre o quadro clínico do paciente. Visto os diversos tipos de exames radiológicos, é importante ressaltar que o modelo corrente, defendido nessa tese, atua sobre imagens em formato digital, independentemente da modalidade de aquisição.

A principal finalidade da aquisição dessas imagens é a análise de seu conteúdo para tomada de decisões que levem à elaboração de diagnósticos mais precisos e realizados com maior segurança. Nesse processo de busca por lesões (anormalidades), os médicos utilizam um conjunto de ferramentas de Processamento de Imagens (PI) que ajudam a manipular as imagens, a diminuir os ruídos, a aumentar o contraste entre regiões específicas, entre outras, melhorando assim o aspecto visual dessas imagens. Essa prática facilita o processo de detecção e reconhecimento humano das possíveis lesões. Porém, atualmente, as ferramentas de PI envolvem muito mais funcionalidades que o simples melhoramento visual. Na literatura da área encontram-se três vertentes de ferramentas de PI que auxiliam no diagnóstico médico, são elas: as ferramentas de detecção, de quantificação e de classificação automática de lesões e/ou regiões de interesse em imagens médicas.

Um *pipeline* básico de Processamento de Imagens Médicas (PIM) para auxílio ao diagnóstico pode envolver um Processamento Global da imagem, a extração de características relevantes de baixo nível, o reconhecimento de padrões e a segmentação de estruturas, como ilustrado na Figura 1.

Figura 1: Pipeline Básica de PIM para Auxílio ao Diagnóstico

Nesse capítulo será colocado em discussão métodos computacionais de processamento, análise, reconhecimento de padrões e extração de características de imagens para um auxílio mais efetivo na detecção e classificação de lesões contidas em imagens radiológicas, bem como o uso desse conhecimento extraído das imagens no auxílio à tomada de decisão diagnóstica e na recuperação de imagens similares.

2.2 Processamento, Análise e Reconhecimento de Padrões em Imagens Médicas

O objetivo principal das técnicas de processamento computacional de imagens é melhorar as condições de manipulação, visualização e interpretação das imagens, além de dar apoio à quantificação de parâmetros, como distribuição de cor, de textura, de forma, de tamanho e de volume de regiões de interesse. Essas medidas fornecem ao médico evidências para um melhor diagnóstico (Rebelo et al. 2011). O processamento, análise e reconhecimento de padrões em imagens consistem, em linhas gerais, na extração de características da imagem ou de alguns objetos/regiões nela contida (processo de análise) e na classificação dessas características extraídas em categorias/padrões existentes (fase do reconhecimento). Cada uma dessas etapas será detalhada a seguir.

2.2.1 Processamento da Imagem

O processamento global das imagens é parte essencial no processo humano de detecção de estruturas (órgãos, lesões, regiões de interesse). Nele pode-se destacar o realce, a aplicação de filtros para redução de ruídos, a compressão da imagem para diminuição espacial (tamanho) ou para re-quantização (profundidade) dos níveis de cinza, a aplicação de transformadas, como Wavelets ou Fourier, entre outras (Gonzalez & Woods 2008). Filtros digitais para remoção de ruídos, detecção de bordas e melhoramento de definição são bastante almejados na área médica. Isso porque a localização precisa das lesões é crucial para identificá-las precisamente e diminuir os riscos de falhas nas intervenções cirúrgicas, radioterapias, biópsias, drenagem de abscessos ou outros procedimentos invasivos.

Uma ferramenta de PI muito utilizada entre os radiologistas durante a visualização e laudo de exames é o “janelamento” da imagem, também conhecido como “realce por alargamento de contraste”. É um método de processamento espacial ponto-a-ponto onde se utiliza uma função (T) de transformação/mapeamento para obter um contraste maior entre determinados valores de níveis de cinza (Jan & Jan 2005):

$$g_{i,k} = \frac{g_{\max}}{f_2 - f_1} (f_{i,k} - f_1)$$

Na fórmula acima, “ f ” representa a imagem original e “ g ” a imagem resultante, sendo $f_{i,k}$ e $g_{i,k}$ os valores do pixel situado na posição (i,k) das imagens original e resultante respectivamente. $g_{\max}$ é o maior valor de pixel da imagem resultante. f_2 e f_1 são os valores de pixel limites (superior e inferior) que definem a “janela” de valores da imagem original que terão seu contraste alargado. Esses valores estão ilustrados na Figura 2. É por meio desse método que determinadas características visuais (como por exemplo regiões mais sutis, não distinguíveis ao olho nu devido ao baixo contraste) podem ser evidenciadas ou suprimidas, melhorando a qualidade da discriminação das estruturas que compõem a imagem. A Figura 3 ilustra a aplicação dessa função de janelamento com três diferentes tamanhos de janelas em imagens de Tomografia Computadorizada da região do tórax. Nesse tipo de imagem, a unidade de valores da escala de níveis de cinza é formada pela “representação” entre a cor preta – ausência de atenuação (absorção de RX pelo tecido) – e a cor branca – atenuação máxima – e é chamada de Unidade Hounsfield (HU), em homenagem ao cientista que desenvolveu a tomografia computadorizada.

Figura 2: Gráfico da Função de Janelamento (*Windowing*)

Figura 3: Aplicação da Função de Janelamento em imagens médicas

O Processamento Global da imagem têm por objetivo a obtenção de condições apropriadas para o reconhecimento humano de estruturas e/ou anormalidades, porém, também podem ser utilizados para permitir realizar o processo automático de reconhecimento de padrões nas imagens e melhorar a segmentação de estruturas. Nesses casos, esse (pré) processamento é alternativo e depende do contexto e das características que serão extraídas.

2.2.2 Detecção de Características

Uma imagem é representada pelo mapeamento espacial quantitativo de uma propriedade física de objetos que a compõe. Assim, em linhas gerais, as imagens são formadas por padrões e/ou objetos que são reconhecidos pelo cérebro humano através de

estímulos sensoriais provocados pela luz (emitida ou refletida pela cena ou imagem) no olho de quem as vê. Esses estímulos sensoriais podem ser modelados numericamente permitindo a representação e/ou manipulação computacional da imagem. Os estímulos sensoriais para os quais as comunidades de Processamento de Imagens e Visão Computacional já conseguiram desenvolver modelos com um relativo grau de maturidade são: cor, textura e forma (Liu et al. 2007).

Cor

A cor é um estímulo visual relacionado com a capacidade de um objeto emitir/refletir/absorver a luz. Como a maioria das imagens radiológicas é monocromática, a propriedade cor passa a ser representada pela variação da intensidade dos níveis de cinza que compõem cada objeto, variando sua tonalidade entre o preto (ausência de luz) e o branco (luminância total). A técnica mais comum utilizada para representação da distribuição das cores desse tipo de imagem é o Histograma de Intensidades, ilustrado na Figura 4b. Esse histograma quantifica a frequência de ocorrência dos valores de luminância apresentada pelos pixels da imagem. Esse modelo é invariante à rotação e translação de objetos na imagem e, quando normalizado, passa a ser invariante também à escala. Sua desvantagem se dá pelo fato de duas imagens visualmente distintas poderem apresentar a mesma frequência de intensidades de pixels. Isso acontece porque esse método estatístico não detém informações sobre a localização espacial das cores. Outro ponto a ser considerado diz respeito à elevada quantidade de características geradas, visto que na maioria das representações por histograma são considerados 256 níveis de cinza. Entretanto, por ser um método muito simples de extração de características e ainda assim alcançando bons resultados na representação das imagens, a literatura o recomenda como *baseline* para várias aplicações (Deselaers et al. 2008).

Diversos trabalhos na área de representação de imagens para recuperação por conteúdo utilizam o modelo de histograma e suas variações. Em (Bugatti et al. 2008), por exemplo, são selecionados os *bins* mais relevantes considerando a entropia do histograma. O trabalho desenvolvido em (Felipe, Traina, et al. 2006) procura caracterizar o histograma considerando seus pontos de saliência e em (Traina et al. 2003) os histogramas são sumarizados através de suas aproximações lineares por partes. Uma alternativa que tem se mostrado mais robusta para a representação de cor é conhecida como *Border/Interior Classification* (BIC) (Stehling et al. 2002). Esse extrator de característica utiliza imagens coloridas (RGB) uniformemente quantizadas em um dado número de cores (p.ex. uma

representação de 6 bits por pixel). Ele apresenta uma representação compacta que consiste na classificação dos pixels da imagem em “pixels de borda” ou “pixels de interior”. Um pixel é classificado como “pixel de borda” se ele estiver na borda da própria imagem ou se pelo menos um de seus 4 vizinhos conectados (superior, inferior, direito ou esquerdo) tiverem uma quantização de cor diferente a apresentada por ele. Um pixel é classificado como “pixel de interior” se seus 4 vizinhos conectados tiverem o mesmo valor quantizado de cor. Assim, o algoritmo de classificação divide a imagem em duas regiões (bordas e interior) e a extração consiste na criação de dois histogramas, um para cada região. No último passo, os dois histogramas gerados são concatenados, gerando o vetor de características representativo da imagem.

Figura 4: Representação de cor de uma (a) Imagem através de um: (b) Histograma Tradicional, (c) Histograma Métrico

Outras variações de histogramas também podem ser encontradas em (Hadjidemetriou et al. 2004) (Bueno 2002). Nesse último artigo foi proposto o Histograma Métrico, que reduz o número de *bins* conservando a curva original do histograma tradicional. Essa redução se dá pelo agrupamento de um conjunto de *bins*, formando-se um bucket², otimizando o custo computacional da operação de comparação entre duas imagens. Porém, por serem

² Região de tamanho (largura e altura) variável que a grosso modo corresponde ao conjunto de *bins* correlacionados de um histograma original.

dependentes da forma do histograma original, apresentam um número de *buckets* variável, problema que o impede de ser comparado pelas funções de distâncias tradicionais. Portanto, (Traina et al. 2002) desenvolveu uma função, chamada Distância Métrica(DM), que calcula a diferença de áreas entre dois histogramas métricos pelo grau de sobreposição entre as curvas de aproximação linear por partes do histograma original. Na Figura 4 são ilustrados os *bins* e os *buckets* de um dado Histograma original e sua versão métrica.

Textura

O estímulo visual identificado como textura é reconhecido pelo sistema visual humano através de características tais como "fina" ou "grosseira", "lisa" ou "áspera", "homogênea" ou "não homogênea", entre outras (Theodoridis & Koutroumbas 2008). Apesar de não contar com uma definição formal, a textura é determinada pela forma como os níveis de cinza estão distribuídos na imagem e a maneira como se relacionam os pixels. Há na literatura uma variedade de técnicas para se extrair características de texturas de imagens (Gonzalez & Woods 2008). Uma abordagem utilizada por várias aplicações é a utilização dos descritores de (Haralick et al. 1973), como por exemplo, Energia, Entropia, Variância, Homogeneidade, entre outros, para análise de um conjunto de Matrizes de Co-ocorrência da imagem. Essa matriz é formada pela contagem da frequência em que duplas de valores dos pixels ocorrem juntas considerando, para cada dupla, a “direção” (normalmente 0°, 45°, 90°, 135°) e a “distância” (normalmente 5 ou 10 pixels) entre os pixels.

Figura 5: Representação de Textura por Matriz de Co-ocorrência

A Figura 5 ilustra a utilização de Matrizes de Co-ocorrência geradas a partir de uma imagem exemplo. Nas Matrizes $P_{d,\theta}$ (onde d é a distância entre os pixels e θ é o ângulo entre eles) os índices das linhas e colunas representam os diferentes valores de níveis de cinza e o valor armazenado em cada um de seus elementos é a frequência com que esses pares de níveis de cinza ocorrem dois a dois, considerando a distância e o ângulo que separam os pixels comparados. Calculada as matrizes de co-ocorrência extrai-se delas os valores propostos por Haralick. Esses valores compõem o vetor final de características da imagem original.

Outra abordagem para a caracterização de texturas de imagens é baseada na utilização de Filtros de Gabor. Nela, descritores como, frequência, orientação, excentricidade e simetria nos padrões de textura são extraídas a partir das funções senóides utilizadas nos filtros de Gabor (Park et al. 2002). Trabalhos recentes mostraram que a Transformada de Fourier também pode ser utilizada para representação de textura em imagens (Chen et al. 2009). Nesse contexto, os descritores mais utilizados estão relacionados à magnitude, entropia, energia e inércia das medidas resultantes da aplicação da transformada na imagem original.

As características de textura têm demonstrado muita eficiência na caracterização de imagens (Huang & Dai 2003). Em imagens médicas, tecidos de mama (Pereira-Jr. et al. 2007), osso (Rubin et al. 2003), encéfalo (Balan et al. 2005) e pulmão (Depeursinge et al. 2012) (Wang et al. 2006) já apresentam trabalhos de reconhecimento de texturas com um bom grau de evolução.

Forma

Encontrar, representar ou definir formas de objetos contidos em uma imagem é uma tarefa bastante difícil. Na literatura, essa caracterização geralmente é obtida a partir da imagem segmentada, onde o objeto de interesse é isolado, fazendo, em seguida, a extração de características de seu contorno (Costa & Jr. 2001). Métodos mais sofisticados utilizam a Transformada Discreta de Fourier para identificar pontos pertencentes ao contorno do objeto de interesse, transformando-os em coeficientes (números complexos) no espaço da frequência. Esses coeficientes são os descritores que representam o objeto (Felipe 2005). Outra técnica, chamada Cadeia de Códigos, aproxima o contorno do objeto por uma sequência de segmentos de reta conectados, dos quais são conhecidos o comprimento e a direção. Nesse modelo a frequência direcional e a curvatura são exemplos de métricas que podem ser utilizadas para representar a forma do objeto (Theodoridis & Koutroumbas 2008).

Em (Zhang & Lu 2001), foi realizada uma comparação entre alguns descritores de forma disponíveis na literatura da época. Medidas de robustez, complexidade computacional

e similaridade perceptual em sistemas de recuperação por conteúdo mostraram o desempenho desses descritores na representação de forma em imagens digitais. Trabalhos recentes vêm mostrando a grande utilização de descritores de forma para representação de estruturas internas (lesões e/ou regiões de interesse) (Felipe, Ribeiro, et al. 2006) (Balan et al. 2007). Esse último trabalho abrange a utilização de descritores de cor, textura e forma em um único método. Nele, o autor utiliza o algoritmo EM (*Expectation and Maximization*) para ajustar um Modelo de Misturas Gaussiano (*Gaussian Mixture Model*) ao histograma da imagem com um classificador baseado nos Campos Aleatórios de Markov (*Markov Random Fields*). Essa variação do método EM/MPM realiza a segmentação da imagem baseada na diferença de textura das classes que a compõe, como ilustrado na Figura 6.

Figura 6: (a) Imagem Original; (b) Imagem Segmentada; (c) Região de Flúido Cérebro-Espinhal; (d) Região de Massa Cinzenta; (e) Região de Massa Branca; (f) Região da Medula Óssea e gordura

Após essa segmentação são computadas as medidas de dimensão fractal, centro de massa ou centróide, massa (ou tamanho), nível de cinza médio e o coeficiente linear utilizado para estimar a dimensão fractal para servirem de descritores de forma para cada uma das regiões encontradas na imagem.

2.2.3 Segmentação de Estruturas

A segmentação resume-se no processo de subdivisão de uma imagem em regiões distintas de interesse. Nesse processo são consideradas propriedades de descontinuidade e homogeneidade dos atributos de baixo nível (pixels) da imagem. Porém, a tarefa não é trivial. Devido aos vários tipos e à diversidade de imagens existentes, não há uma solução única para todas as aplicações de segmentação (Gonzalez & Woods 2008). Esse fato consolida a necessidade da existência de diversas técnicas e métodos que satisfaçam os diferentes contextos de imagens.

Um método relativamente simples, bastante encontrado na literatura é o processo de

Limiarização,

$$g(x,y) = \begin{cases} 0, & \text{se } \min(f) < f(x,y) < T_1 \\ 1, & \text{se } T_1 < f(x,y) < T_2 \\ \vdots & \vdots \quad \quad \quad \vdots \\ m, & \text{se } T_m < f(x,y) < \max(f) \end{cases}$$

onde a imagem resultante $g(x,y)$ é obtida através da uniformização dos valores de pixel pertencentes a uma mesma faixa de valores, delimitados pelos limiares ($T_1 \dots T_m$), da imagem original $f(x,y)$. Nesse caso, $m+1$ será o número de classes/regiões distintas na imagem resultante, e os pixels compreendidos em uma mesma faixa de valores são classificados como pertencentes à mesma região. O problema nesse método é determinar automaticamente os valores dos limiares (T_i). A maioria das soluções automáticas baseia-se na distribuição do histograma da imagem para inferir o(s) melhor(es) limiar(es). É o caso da Técnica de Otsu que realiza a escolha dos limiares baseada na maximização da variância entre duas partes do Histograma, como ilustrado na Figura 7. Na Tabela 1 é apresentado um resumo dos métodos mais comuns de determinação dos valores de limiar.

Figura 7: Exemplo de uma (a) Imagem de Ressonância e sua (c) segmentação baseada na (b) identificação de limiar baseado na Técnica de Otsu

Tabela 1: Resumo das principais técnicas de limiarização de Imagens

Técnica	Descrição Resumida	Observação
Seleção Manual	Com base na visualização do resultado, o usuário seleciona os valores de limiar	Método semi-automático, dependente do usuário
Pontos de Mínimo (vales)	Seleciona os valores para limiar com base nos “vales” existentes no histograma da imagem	Método automático, porém sensível a ruídos
Técnica de Otsu	Escolhe os limiares que maximizam a medida de variância entre as partes do histograma	Método automático e bastante utilizado na literatura

Existem também métodos mais sofisticados para segmentação de estruturas (Dougherty 2009). Os métodos baseados em detecção de bordas procuram pelos limites entre duas regiões com propriedades relativamente distintas de níveis de cinza. Para essa tarefa normalmente utiliza-se um operador local diferencial. Podem ser utilizados os Operadores de Sobel, o Laplaciano ou ainda o de Prewitt (Gonzalez & Woods 2008). Após essa etapa,

normalmente faz-se necessário uma operação de conexão dos fragmentos encontrados, gerando os contornos dos objetos de interesse (Ribeiro 2008). Um exemplo das etapas de detecção de bordas utilizando os Operadores de Sobel pode ser visto na Figura 8.

Figura 8: (a) Imagem de RM Original. Resultado da aplicação dos operadores de Sobel para obtenção de (b) Gx, (c) Gy e da (d) Imagem Gradiente Completa

Figura 9: (a) Imagem de CT de Pulmão; (b) Aplicação de crescimento de região para segmentação do pulmão esquerdo

Os métodos baseados em regiões fundamentam-se na observação do interior dos objetos, partindo do princípio de que os pixels que compõem um objeto têm propriedades similares, enquanto que os pixels de objetos distintos não. Esse é o caso da técnica de Divisão e Fusão de Regiões (*Split and Merge*) e da técnica Crescimento de Região (*Region Growing*), na qual pixels iniciais são escolhidos e iterativamente agrupados a pixels vizinhos com características semelhantes. Um exemplo de aplicação desse método é ilustrado na Figura 9. Outras técnicas utilizam um conjunto de pixels “sementes”, a partir das quais é realizado o crescimento das regiões por meio da inclusão de pixels vizinhos que tenham atributos similares. Essa abordagem engloba técnicas como a aplicação da Transformada de *Watersheds* e o Modelo de Contorno Ativo (*snakes*), onde os contornos são atraídos para as bordas dos objetos da imagem por um processo de convergência, detalhado em (Kass et al. 1988).

Atualmente, abordagens probabilísticas de segmentação têm sido bastante difundidas na área, principalmente porque os objetos presentes em imagens médicas são caracterizados por microtexturas de comportamento aleatório. Esses algoritmos estatísticos consideram os

pixels de uma imagem como variáveis aleatórias que formam um campo aleatório bidimensional. A representação de cada objeto da imagem pode ser feita construindo um campo de rótulos/classes (dado ausente) a partir do campo aleatório inicial (dado observado). Os Campos Aleatórios de Markov (*Markov Random Fields*) são bastante adequados para a modelagem de microtexturas, pois definem uma função de probabilidade por meio de características locais de vizinhança (Gerhardinger 2006). A Figura 6 ilustra os resultados de segmentação obtidos por um método de abordagem probabilística, considerado uma variação do Método EM/MPM, proposto e explicado com mais detalhes em (Balan et al. 2007).

Ainda na área médica, abordagens recentes utilizam informações registradas em Atlas de Imagens, composto por estruturas anatômicas delineadas e rotuladas com referência a uma imagem objetivo. Mais detalhes podem ser encontrados em (Lötjönen et al. 2010) (Chupin et al. 2009).

Mesmo com tantas técnicas e por não haver uma solução única para todas as aplicações da segmentação, o desafio em cada aplicação é encontrar a técnica de segmentação que melhor se encaixa ao seu contexto. Além disso, a segmentação de imagens nas aplicações médicas consiste em uma das principais etapas para a análise automática de imagens, pois a partir dela podem ser delimitados os objetos sobre os quais se deseja extrair padrões.

2.2.4 Reconhecimento das Características

Os valores numéricos extraídos pelos processos de detecção de características podem agora ser utilizados como dados de entrada para os algoritmos de reconhecimento. Essas características poderão ser classificadas de acordo com padrões pré-estabelecidos ou ainda separadas em grupos/categorias que desempenham comportamentos ou distribuição semelhantes.

Dentre os métodos para classificação e agrupamento de características encontrados na literatura (Bellazzi & Zupan 2008), um método bastante conhecido e utilizado por apresentar uma classificação transparente ao usuário é a Árvore de Decisão. Árvores de Decisão usam particionamento recursivo dos dados, sugerindo regras de decisão na forma de SE (condição baseada nos valores dos atributos) e ENTÃO (valor de saída), para se chegar a uma classificação final. Há também métodos estatísticos poderosos utilizados na tomada de decisão, um deles é a Regressão Logística. Nesse método utiliza-se uma técnica baseada na estimação da maximização da função de verossimilhança para determinar os coeficientes responsáveis por modelar uma saída de dois valores que, geralmente, representam a ocorrência e a não ocorrência de algum evento. Na área computacional, um método que tem

apresentado boa performance preditiva são as chamadas Redes Neurais. As Redes Neurais permitem modelar relações não lineares complexas, apresentando vantagens sobre métodos mais simples (como Regressão Logística, por exemplo). Porém, suas desvantagens incluem alto custo computacional na fase de treinamento e a difícil interpretação da indução do modelo pelos especialistas do domínio.

Atualmente, um dos algoritmos de classificação mais poderosos em termos de acurácia e predição tem sido a *Support Vector Machine* (SVM)(Thawait et al. 2013). Ele, resumidamente, busca encontrar um hiperplano que separa os exemplos de diferentes saídas. Chamado de vetor suporte (*support vector*), esse hiperplano gera um classificador linear (no caso de problemas de duas classes) que divide o espaço dos objetos em dois grupos. As SVMs também são utilizadas com outros núcleos não lineares que, na essência, transformam o espaço do atributo original para um novo espaço, com dimensão mais alta, no qual o classificador linear é inferido. Essa metodologia também não é de difícil interpretação lógica por parte dos especialistas do domínio, porém, se o interesse for apenas na acurácia preditiva, as SVMs são um forte concorrente para as redes neurais artificiais, especialmente pelo seu desempenho, além de serem mais robustas e depender menos da seleção específica dos parâmetros do método (Cortes & Vapnik 1995).

2.3 Sistemas de Diagnóstico Auxiliado por Computador (CAD)

Partindo de imagens processadas e/ou segmentadas, bem como suas características extraídas e/ou reconhecidas (classificadas), o próximo passo é a utilização dessas informações como base para o auxílio ao diagnóstico médico. Sistemas CAD têm por objetivos principais: apontarem possíveis problemas em uma imagem e/ou fornecerem uma segunda opinião para os médicos radiologistas e estudantes de medicina. Eles ajudam melhorando a precisão e a consistência dos diagnósticos radiológicos, além de reduzirem o tempo de leitura e análise das imagens (Huang et al. 2013)(Arimura et al. 2009). As técnicas para o desenvolvimento de uma aplicação CAD para imagens médicas utilizam processamento, análise e classificação dos atributos extraídos das imagens (como já descrito no tópico anterior) e incluem etapas/técnicas de seleção de atributos, algoritmos genéticos, sistemas especialistas baseados em regras de decisão, métodos estatísticos, redes neurais artificiais, ontologias, entre outros (Doi 2005). Nos últimos anos, vários sistemas CAD tem sido desenvolvidos visando o auxílio à detecção de lesões (CADd) e também visando o auxílio à classificação diagnóstica e tomada de decisão (CADx) (Rahman et al. 2010)(Doi 2007).

2.3.1 Auxílio à Detecção de Lesões

Por meio de varredura na imagem digital, os algoritmos de detecção automática buscam a localização de regiões que contenham padrões radiológicos que indiquem uma lesão. Essa análise computacional utiliza características visuais automaticamente extraídas das imagens (por exemplo, as características estudadas na Seção 2.2.2). Nessa análise computacional, o algoritmo de detecção se preocupa com o padrão normal e, qualquer comportamento que foge desse padrão é tido como anormal. Não há uma preocupação em classificá-los de acordo com as especificações de tipos de anormalidades. Nesse tipo de auxílio, após a detecção das regiões suspeitas, a análise e classificação da lesão ficam a cargo do radiologista que analisa a imagem.

Por meio de exames de RX e/ou CT de tórax, há uma série de patologias pulmonares possíveis de serem detectadas de forma automática (Kasai et al. 2008). Esse auxílio à detecção é importante na prática do diagnóstico por imagem, pois estudos mostram que a taxa de acerto do radiologista chega a aumentar 10% quando esse faz uso de uma sistema CAD. Essas pesquisas mostraram também que o uso de redes neurais artificiais (Fukushima et al. 2004) e características de textura (Huber et al. 2010)(Wang et al. 2010) são ferramentas poderosas na detecção de lesões intersticiais de pulmão. Outros trabalhos mostraram ainda a eficiência na detecção de nódulos pulmonares (Park et al. 2009)(Donovana et al. 2008). A detecção de lesões em imagens de mama também é bastante importante. Sistemas CAD auxiliam o médico a diagnosticar o câncer de mama e outras lesões numa fase inicial onde existe uma maior chance de tratamento e cura (Rangayyan et al. 2007). Mais recentemente, grandes grupos de pesquisa têm buscado o desenvolvimento de sistemas CAD para detecção de doenças cerebrais em imagens de Ressonância Magnética (Arimura et al. 2009), Tomografia Computadorizada (Chan & Huang 2008), além de sistemas para viabilização de trabalhos cooperativos e cooperação diagnóstica entre diferentes centros médicos (Moreno et al. 2012).

2.3.2 Auxílio à classificação diagnóstica

Nos sistemas de auxílio à classificação, o processo acontece de modo semelhante ao processo de reconhecimento de padrões em imagens (vistos na Seção 2.2.4), entretanto, esse tipo de sistema CAD sugere uma "segunda opinião" aos radiologistas (e não uma decisão propriamente dita). O auxílio resume-se então na quantificação das características das imagens e na sua classificação em padrões normais ou anormais (incluindo suas especificações, como por exemplo, uso de características de forma de uma estrutura para

associá-la a um tumor maligno ou benigno). É importante ressaltar que após a apresentação da “segunda opinião”, o diagnóstico final deverá ser feito pelo radiologista responsável pela análise do exame.

Quando o radiologista detecta a presença de um tumor (anomalia), ele tenta distinguir, pelas características visuais, o tipo da lesão. Embora existam regras gerais que diferenciem lesões malignas ou benignas, existe uma grande variedade na interpretação das mesmas. Estudos mostram que apenas 10% a 20% dos tecidos submetidos a um procedimento cirúrgico de biopsia são confirmados como tumor maligno e que essa grande faixa de intervenções desnecessárias tem sido diminuída com o uso de sistemas de CAD (Przelaskowski 2008). O sistema desenvolvido por (Armato et al. 2003) realiza uma classificação automática através de uma análise discriminante linear das características de forma de nódulos de pulmão para diferenciar nódulos malignos e nódulos benignos em imagens de CT de pulmão. O sistema de (Depeursinge et al. 2008) realiza essa tarefa de classificação de tecidos pulmonares, porém utilizando não só o processamento das imagens, mas também dados clínicos extraídos do contexto onde elas estão inseridas. A classificação automática de tecidos da mama em exames de mamografia também está em franco desenvolvimento (Houssami et al. 2009) (Sahiner et al. 2009). Em (Freer & Ulissey 2001) foi apresentado um estudo mostrando que o uso de CAD promoveu um ganho de 20% no diagnóstico de tumores de mama.

Tanto a detecção quanto a classificação automática de lesões envolvem a localização pelo computador de regiões contendo padrões radiológicos que podem indicar uma lesão. Essa análise computacional automática utiliza características visuais automaticamente extraídas das imagens. No entanto, é necessário que em uma etapa prévia sejam definidos, com auxílio de especialistas, quais são os atributos clinicamente significativos na discriminação das lesões.

2.3.3 Desempenho dos Sistemas CAD

Parte essencial para escolha de determinada técnica de auxílio ao diagnóstico é saber se seu desempenho realmente é eficiente, satisfaz os médicos e faz diferença na prática da medicina. Um dos métodos mais utilizados para medir a eficácia de um sistema CAD é a curva ROC (*Receiver Operating Characteristic*) (Prati et al. 2008). Para entender o funcionamento dessa curva é importante saber dos conceitos apresentados na Tabela 2. Quando o resultado de um teste é positivo, indicando que há uma lesão, ele pode ser verdadeiro (ocasião onde essa lesão realmente existe, sendo assim um “Verdadeiro Positivo”)

ou pode ser falso (ocasião em que na realidade não há uma lesão e o teste errou a resposta, sendo assim um “Falso Positivo”). Quando o resultado de um teste dá negativo, indicando que não há uma lesão, ele pode ser verdadeiro (ocasião onde a lesão realmente não existe, sendo assim um “Verdadeiro Negativo”) ou pode ser falso (ocasião onde essa lesão na realidade existe e o teste errou a resposta, sendo assim um “Falso Negativo”). Quando se lida com doenças, o erro mais grave nos testes é aquele em que seu resultado dá negativo (indicando que não há uma doença) onde na realidade a doença existe. Isso porque o paciente pode deixar de ser tratado, o que o levaria a possíveis danos irreversíveis. O outro erro associado ao resultado do teste também é sério, porém não apresenta um impacto muito grande no risco de morte do paciente. Nele, o resultado do teste é positivo (indicando a presença da doença), quando na realidade a doença não existe no paciente. Nesse caso, o paciente poderá ser submetido a um tratamento clínico para tratar uma doença que ele não tem. Baseado nesses conceitos, as duas medidas mais importantes utilizadas na análise de eficiência dos sistemas CAD foram desenvolvidas, que são a *sensibilidade* e a *especificidade*, também explicadas na Tabela 2.

Tabela 2: Conceitos de Sensibilidade e Especificidade

	Há Doença (D+)	Não Há Doença (D-)
Resultado Positivo (R+)	Verdadeiros Positivos (TP)	Falsos Positivos (FP)
Resultado Negativo (R-)	Falsos Negativos (FN)	Verdadeiros Negativos (TN)
	Notação	Interpretação
<i>Sensibilidade</i>	$P(R+ D+) = \frac{TP}{TP + FN}$	Probabilidade de o resultado dar positivo, dado que o paciente está doente. Obtido pela proporção dos resultados positivos que o teste acertou (TP), pelo total de pacientes realmente doentes (TP + FN)
<i>Especificidade</i>	$P(R- D-) = \frac{TN}{TN + FP}$	Probabilidade de o resultado dar negativo, dado que o paciente não está doente. Obtido pela proporção dos resultados negativos que o teste acertou (TN), pelo total de pacientes realmente não doentes (TN + FP)

A curva ROC é o gráfico da *sensibilidade* (fração de verdadeiros positivos) versus *1-especificidade* (fração de falsos positivos), onde os pontos do gráfico são calculados a partir da escolha de diferentes parâmetros de execução do método em avaliação. Essa curva é ilustrada na Figura 10. A partir dessa curva é possível medir a precisão do método através da área abaixo da curva. Nesse caso, o valor da área varia de 0.5 (pior caso, quando o método

mostra um comportamento aleatório) até 1.0 (melhor caso). Assim, quanto mais perto da borda superior estiver a curva, melhor é o método.

Figura 10: Exemplo de Curva ROC

2.4 Considerações Finais

Este capítulo apresentou tópicos relacionados ao Processamento de Imagens Médicas para auxílio ao diagnóstico. Nele, os algoritmos de processamento e análise de imagens foram considerados como aqueles que fazem: adequação da qualidade da imagem para reconhecimento humano de estruturas, detecção de alterações em sequências de pixels, reconhecimento e classificação de cores, texturas, formas, contornos e segmentação. O foco deste capítulo foram análises que podem ser utilizadas para retirada de valores numéricos que representem o conteúdo visual da imagem, ou o seu conteúdo. Foi mostrado que esse conhecimento extraído das características de baixo e médio nível das imagens pode ser utilizado na descoberta e reconhecimento de padrões e, conseqüentemente, é o ponto de partida para os Sistemas CAD (*Computer Aided Diagnosis*). Contudo, devido à grande amplitude de possibilidades de processamentos e análises, a maioria das pesquisas desenvolvidas tenta concentrar-se em conjuntos específicos de imagens, com objetivos clínicos bem definidos.

No próximo capítulo é apresentado o que pode ser considerado como um terceiro tipo de ferramenta CAD. Aquela que, apesar de não detectar e nem classificar lesões existentes na imagem, ajuda na tomada de decisão diagnóstica oferecendo informações sobre os casos similares. Esses sistemas, conhecidos como CBIR (*Content-Based Image Retrieval*), também utilizam o conhecimento abordado neste capítulo.

Capítulo 3 - Recuperação de Imagens Baseada em Conteúdo

3.1 Considerações Iniciais

A busca de imagens em grandes bases de dados tem sido realizada por meio de duas abordagens principais. A primeira necessita de uma associação de texto descritivo às imagens armazenadas. Nessa abordagem, a recuperação baseia-se nessa descrição. Embora essa metodologia seja simples, ela possui várias limitações, pois exige esforço de inserção manual das informações e muitas dessas informações são subjetivas, variando de acordo com o entendimento da pessoa que as inclui, o que gera uma grande dependência da intervenção do usuário no sistema.

Figura 11: Visão Geral de um Sistema CBIR para imagens médicas

A segunda abordagem é conhecida como Recuperação de Imagens Baseada em Conteúdo (CBIR – *Content-Based Image Retrieval*) (Long et al. 2009). Nela, a recuperação eficiente de imagens em grandes bases de dados é realizada sem a utilização de chaves de

busca tradicionais, baseadas em números ou textos, como nome do paciente, data do exame ou mesmo uma descrição da imagem. Nessa abordagem as chaves de busca são as próprias imagens, representadas por seu conteúdo intrínseco. Esse termo “conteúdo intrínseco” diz respeito às características visuais próprias das imagens, tais como cor, textura, forma, posição espacial de elementos ou de regiões, entre outros (Torres & Falcão 2006). A Figura 11 ilustra uma visão geral de sistemas CBIR para imagens médicas e neste capítulo são abordados os principais tópicos relacionados a esses sistemas.

3.2 Representação do Conteúdo Intrínseco à Imagem

A extração de características é realizada por técnicas de processamento de imagens seguida de uma análise detalhada de seus níveis de cinza (características de baixo nível). Programas computacionais de detecção/extração de características e reconhecimento de padrões calculam valores numéricos que são utilizados como modelos quantitativos para descreverem características visuais da imagem. Os valores extraídos, descritos na Seção 2.2, são informações que podem servir como base para cálculos envolvendo similaridade (Beecks et al. 2013).

As consultas baseadas em conteúdo das imagens podem ser classificadas em três níveis, conforme foi proposto inicialmente por (Eakins & Graham 1999) e tem sido grandemente usado na literatura:

- **Nível 1 (Baixo Nível):** Recuperação por meio de características primitivas como cor, textura e/ou forma. Um exemplo de consulta desse tipo seria: “Recupere imagens similares a essa imagem de referência”
- **Nível 2 (Alto Nível):** Recuperação realizada com base em características derivadas de alguma inferência lógica simples. Um exemplo seria: “Recupere imagens de peixe”
- **Nível 3 (Alto Nível):** Recuperação a partir de atributos abstratos, envolvendo raciocínio complexo do tipo “Recupere imagens de pessoas alegres”

A classificação acima exemplifica o nível 1 com uma consulta por conteúdo baseada em imagem exemplo (ou referência), utilizando características intrínsecas/primitivas à imagem. Os outros dois níveis utilizam consultas baseada na semântica do conteúdo da imagem. Como este trabalho é focado em aplicações CBIR para imagens médicas, as consultas por conteúdo para auxílio ao diagnóstico serão sempre baseadas em imagem exemplo. Esse fato torna a classificação acima insuficiente para discriminação de diferentes

consultas por referência. Nessas condições, não foi encontrado na literatura uma divisão formal e consolidada dos diferentes níveis para esse tipo de consulta (por referência). Com isso, este trabalho propõe uma classificação própria, apresentada na Seção 5.2 desta tese. Toda a sistematização para sistemas CBIR que consideram a percepção do usuário já na fase de construção (Sistemas Perceptual-CBIR) defendida nesta tese considera a classificação citada, também dividida em três níveis, possibilitando a diferenciação de consultas que incluem ou não características de percepção do usuário.

Representação Global e Local de Conteúdo Intrínseco das Imagens

É comum encontrar na literatura o termo “característica global” da imagem para se referir a processos de extração de características que consideram toda a extensão da imagem como parâmetro para extração, ou seja, sem delimitação de qualquer região de interesse ou mesmo estrutura a ser segmentada (Vimina & Jacob 2012). Por outro lado, características consideradas “locais” são aquelas retiradas de apenas uma parte da imagem (região de interesse específica), podendo ser um órgão, estrutura ou objeto pré-definido (Hota et al. 2010). Na abordagem local normalmente se representa o todo pela parte significativa. Alguns estudos mostram que características locais, por normalmente serem mais específicas a um contexto pré-definido, representam melhor as imagens daquele contexto (Bannour et al. 2009), outros defendem a combinação dos dois tipos de características para não perder nenhum aspecto relevante da imagem (Andrade et al. 2012).

Combinação de Múltiplos Descritores

O sistema humano de comparação entre imagens é complexo e utiliza várias características e parâmetros de percepção associados de modo subjetivo. Em diversos casos, um único extrator é insuficiente para expressar similaridade de características visuais. Uma tentativa de aproximar os sistemas CBIR desse modelo real de comparação humana é o desenvolvimento de técnicas para associação e combinação de diferentes descritores de características. Essa ideia é explorada em (Bueno et al. 2009), que desenvolveu um método para utilização e ponderação de multi-descritores utilizando a Métrica Produto e em (Faria et al. 2010), que compara algoritmos de aprendizado que combinam informações vindas de diferentes descritores de características. Nesse último trabalho, os resultados mostraram que combinar elementos de vários descritores supera em muito os resultados obtidos pelo melhor descritor individual. Essa metodologia tem se mostrado bastante eficiente no aumento da precisão das consultas, porém o uso de um número cada vez mais elevado de características

para representar as imagens pode criar um grande problema, conhecido como “*maldição da alta dimensionalidade*” (Malcok et al. 2006). Nesse caso, as estruturas de indexação degradam-se e o poder de representatividade de cada característica diminui consideravelmente, tornando os processos de indexação e recuperação mais lentos e ineficientes. Esse fenômeno acontece não só porque a alta dimensionalidade pode aumentar a sobreposição de regiões no espaço, mas também porque ela diminui a cardinalidade e a taxa de ocupação dos nós das árvores de indexação e aumenta o custo de processamento (comparação entre os objetos, cálculo de distância). Além desses problemas, há também uma grande preocupação com a escolha da função de distância adequada para o contexto. Isso porque o conceito que é utilizado para espaços bidimensionais ou tridimensionais acaba não apresentando o mesmo comportamento à medida que a dimensionalidade do espaço aumenta, levando algumas funções de distância a não serem representativas nesses espaços de alta dimensionalidade (Jeong et al. 2009), pois não conseguem separar os dados.

Redução da Dimensionalidade

Para resolver o problema dessa maldição, além do desenvolvimento de métodos de acesso para bases de dados de alta dimensionalidade (Malcok et al. 2006), há também a perspectiva do desenvolvimento de técnicas para redução do tamanho dos vetores de características. Ou seja, um processo baseado na seleção de um número menor de atributos, suficientemente relevantes para representar as características de determinado conjunto de imagens. Há na literatura vários métodos para redução da dimensionalidade. Em (Sousa 2006) utiliza-se do conceito de dimensão fractal para realizar tal redução. A dimensão fractal é utilizada como forma de medir a irregularidade dos objetos naturais, porém, nesses trabalhos, ela tem servido como parâmetro de aproximação da dimensão intrínseca (dimensão de um dado conjunto de dados a qual diz respeito à dimensão espacial dos objetos representados por este) que prediz a quantidade de atributos necessários para representar e analisar objetos complexos sem perda de informação. A PCA (*Principal Component Analysis*), outra metodologia para redução de dimensionalidade, transforma pontos de um espaço original de alta dimensão em outro espaço de menor dimensão. Porém, essa técnica é eficaz para dados que são globalmente correlacionados, fato que normalmente não é encontrado em dados reais. Para dados localmente correlacionados ela gera uma perda significativa de informação, o que acarreta no aparecimento de falsos positivos no momento da consulta. Além disso, a PCA não retém informação de quais são as dimensões mais significativas.

Toda a técnica de redução de dimensionalidade aplicada ao contexto de CBIR tem por objetivo melhorar a discriminação dos dados, aumentar a eficiência das consultas por similaridade e consequentemente melhorar o resultado. Outros métodos de redução da dimensionalidade podem ser encontrados em (Pirolla et al. 2012) e (Huang et al. 2008).

3.3 Consultas por similaridade: Definição, Suporte e Estruturas de Indexação para Dados Métricos

As novas direções de pesquisa para sistemas gerenciadores de base de dados visam lidar com tipo de dados complexos, tais como imagens, sons em seus vários formatos, hipertextos, sequências de proteínas e impressão digital, entre outros (Cordeiro et al. 2013). A maioria das características extraídas desses tipos de dados complexos pode ser vista como pontos multidimensionais em um espaço n -dimensional, como é o caso das características extraídas de imagens médicas (especificadas nas Seções 2.2.2 e 3.2). Embora existam métodos de acesso espaciais desenvolvidos para gerenciar dados de alta dimensão, é necessário destacar que em algumas ocasiões não é possível ter todos os vetores de características obtidos com o mesmo número de componentes (dimensões) e, portanto, não é adequado utilizar nenhum método de acesso espacial. Para tais situações foram desenvolvidos os Métodos de Acesso Métricos – MAMs, que englobam tanto dados espaciais com dimensão definida quanto dados adimensionais. Eles organizam um grande conjunto de dados métricos permitindo inserções, exclusões e pesquisas, baseando-se somente nas distâncias entre itens de dados.

Dentre as principais estruturas de indexação para espaços métricos encontradas na literatura estão a M-Tree (Ciaccia et al. 1997), a Slim-Tree (Traina Jr. et al. 2000), a DF-Tree (Traina Jr. et al. 2002), a DBM-Tree (Vieira 2004), a OMNI-Family (Traina Jr. et al. 2007) e a Onion-Tree (Carélo et al. 2011). Algumas dessas estruturas já atingiram um grau de eficiência bom o bastante para serem utilizados em situações práticas. Esse é o caso da Slim-Tree que é uma estrutura balanceada e dinâmica, que permite inserções posteriores à criação da árvore. Quando comparada com a M-tree nas mesmas condições, sempre a sobrepujou, tanto em termos de número de acessos a disco quanto em termos de número de distâncias calculadas para responder a consultas por abrangência e, portanto, também em tempo total de execução (Traina Jr. et al. 2002). Sendo assim, os MAM são ótimas estruturas para dar suporte a buscas

por similaridade, pois as únicas informações necessárias para indexação são os objetos e as distâncias entre eles.

Busca por similaridade é aquela em que se considera quão “próximos” (similares) dois dados (objetos) são entre si. A similaridade entre os dados é definida através de uma função distância, ou função de “dissimilaridade” $d(O_i, O_j)$, que retorna zero se ambos os objetos O_i e O_j forem idênticos, e um valor positivo que aumenta quanto maior for a distância (ou dissimilaridade) entre os objetos. Uma função de distância métrica é a base na construção de MAMs (Traina et al. 2002). Esses métodos, quando construídos sobre as características extraídas das imagens, são adequados para responder consultas por similaridade, tais como as consultas *k-nearest neighbor query* (*k*-NN), que retornam os *k* objetos mais próximos do objeto de busca, como, por exemplo, “encontre as 5 imagens mais semelhantes da imagem de busca dada”. Outro tipo de consulta possível é a consulta por abrangência (*range-query*), que retorna todos os objetos cuja distância ao centro do objeto de busca é menor ou igual ao raio fornecido. Por exemplo, “encontre todas as imagens que se encontram a uma distância de 10 unidades da imagem de busca dada”.

Muitas medidas de similaridade estão sendo desenvolvidas visando otimizar o processo de recuperação de imagens baseada em conteúdo (Felipe et al. 2009). A Tabela 3 apresenta as principais medidas/funções encontradas na literatura (Bugatti 2008), suas fórmulas e um breve resumo descritivo. Nela, as medidas/funções são categorizadas de acordo com suas origens teóricas (Liu et al. 2008). Para melhor interpretação dos dados da tabela abaixo, foi considerado para todas as funções a existência de dois vetores de características

$$X = \{x_1, \dots, x_n\} \text{ e } Y = \{y_1, \dots, y_n\},$$

sendo a distância entre os dois denotados por $d(X,Y)$.

Por existirem várias opções de medidas de similaridade, muitas vezes, a escolha da função a ser utilizada em um sistema CBIR é feita sem critério ou fundamentação teórica. Essa escolha pode afetar o desempenho do sistema, visto que cada uma das funções apresenta um comportamento diferente com relação aos dados comparados. Cada contexto de aplicação e cada modelo de extratores de características carregam consigo suas peculiaridades semânticas e uma distribuição estatística própria que devem ser consideradas na escolha da melhor função de distância para aquele determinado contexto.

Tabela 3: Principais Medidas/Funções de Distância

Tipo	Nome	Fórmula	Resumo Descritivo
Distâncias Geométricas	Família Minkowski (Lp)	L_1 $d_{L_1}(X, Y) = \sum_{i=1}^n x_i - y_i $	Também denominada <i>City Block</i> ou <i>Manhattan</i> , corresponde ao somatório do módulo das diferenças entre as coordenadas.
		L_2 $d_{L_2}(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$	Conhecida como distância Euclidiana, corresponde ao somatório do quadrado das diferenças entre as coordenadas
		L_{∞} $d_{L_{\infty}}(X, Y) = \max_{i=1}^n x_i - y_i $	Também conhecida como <i>Infinity</i> ou <i>Chebychev</i> , corresponde ao máximo valor entre os valores obtidos pela diferença entre as coordenadas
	Distância Mahalanobis	$d_M(X, Y) = \sqrt{(y - x)^T A^{-1} (y - x)}$	Na equação, 'A' é a matriz de covariância entre os vetores de atributos Y e X. Tal matriz é incorporada no cálculo de distância para considerar o efeito da correlação entre os atributos
	Distância Quadrática	$d_Q(X, Y) = \sqrt{(x - y)^T A (x - y)}$	Onde A = [a _{ij}] é uma matriz N por N de elementos a _{ij} que denotam a similaridade entre as dimensões i e j. Também x e y dizem respeito a atributos dos vetores de características
	Distância Canberra	$d_C(X, Y) = \sum_{i=1}^n \frac{ x_i - y_i }{ x_i + y_i }$	Consiste de um cálculo simples envolvendo a diferença absoluta dos valores das características de um vetor, dividida pela soma absoluta dos mesmos
	Distância Cosseno	$d_{Cos}(X, Y) = 1 - \cos \theta = 1 - \frac{X^T Y}{\ X\ \ Y\ }$	Considera o ângulo entre dois vetores R e S, dispensando a informação de magnitude dos mesmos. Sua definição parte do produto escalar de dois vetores.
Teoria da Informação	Distância Bray-Curtis	$d_{BC}(X, Y) = \sum_{i=1}^n \frac{ x_i - y_i }{x_i + y_i}$	Semelhante à distância Canberra, porém o denominador normaliza a diferença absoluta dos valores das características
	Divergência de Kullback-Leibler	$d_{KL}(X, Y) = \sum_{i=1}^n y_i \log \frac{y_i}{x_i}$	Mensura quão ineficiente em média seria codificar um determinado vetor de características a partir de outro, utilizado como referência
	Divergência de Jeffrey	$d_J(X, Y) = \sum_{i=1}^n \left(y_i \log \frac{y_i}{m_i} + x_i \log \frac{x_i}{m_i} \right)$ onde $m_i = (y_i + x_i)/2$	Derivada da Divergência de Kullback-Leibler, porém é simétrica e apresenta um comportamento numericamente mais estável e robusto em relação a ruídos e ao tamanho do vetor
Medida Estatística	Valor Estatístico χ^2	$d_{\chi^2}(X, Y) = \sum_{i=1}^n \frac{(y_i - m_i)^2}{m_i}$ onde $m_i = (y_i + x_i)/2$	Função que valoriza as elevadas discrepâncias existentes entre dois vetores de características e mede o quão improvável é a ocorrência da distribuição do vetor comparado em relação ao vetor referência

3.4 Sistemas CBIR: Estado da Arte e Desafios

Há na literatura vários projetos de construção de sistemas CBIR para área médica (Town 2013). Apesar do estabelecimento de conceitos genéricos para implementação desses sistemas (Guld et al. 2007), apenas alguns deles explicam qual(is) a(s) metodologia(s) para a extração de características, qual(is) a(s) métrica(s) de comparação utilizada ou ainda o(s) método(s) de armazenamento e recuperação dessas imagens em grandes bases de dados. O SMIRE (*Similar Medical Image Retrieval Engine*), descrito em (Cheng et al. 2005),

apresentou ótimos resultados utilizando coeficientes wavelets e histogramas de níveis de cinza. Uma métrica própria de comparação entre as 322 características de cada imagem foi proposta como parte do método utilizado e a implementação de um algoritmo de realimentação manual ajudou na obtenção de melhores resultados. Já o sistema FIRE (*Flexible Image Retrieval Engine*) (Deselaers et al. 2006) utiliza características de textura e cor associadas, extraídas através de histogramas de co-ocorrência. A métrica utilizada para comparação é a distância Euclidiana e a Divergência de Jeffrey, permitindo também o uso de Realimentação de Relevância. Cada um dos sistemas foi testado com imagens de um domínio específico, o que dificulta a avaliação e comparação entre eles. Porém, estudos recentes estão preocupados em possibilitar uma avaliação justa e comparações entre diferentes sistemas (Müller et al. 2004) delimitando alguns parâmetros de comparação entre sistemas (Deserno et al. 2007) na tentativa de padronizar e validar a construção de ferramentas e Sistemas CBIR.

Focado em imagens de coluna, alguns trabalhos utilizam métodos estatísticos (características de Haralick e Espectro de Textura) e medidas de curvatura para representação de características e comparação de imagens (Kumaran & Bhavani 2012) (Medina et al. 2012). Nesses casos, os algoritmos dispõem de métodos globais, considerando toda a imagem como objeto para extração de características, para gerar um único vetor de característica para cada imagem. Ambos os trabalhos dão suporte ao diagnóstico e tratamento de escoliose. No último caso (Medina et al. 2012), apesar da aplicação de uma abordagem global, há a extração de características de nível 3 (conforme definido na Seção 5.2.1), ou seja, extraindo medidas específicas da curvatura da coluna em imagens de Raio-X de pacientes com escoliose. Recentemente, o *Lister Hill National Center for Biomedical Communications* juntamente com a *National Library of Medicine* (NLM) está desenvolvendo um CBIR para recuperação de casos similares e auxílio a diagnóstico em patologias na coluna vertebral. Esse sistema suporta consultas híbridas, utilizando textos agregados aos exames bem como conteúdo intrínseco das imagens de Raio-X da coluna. As características utilizadas para comparação das imagens são extraídas de Regiões de Interesse (ROIs) – corpos vertebrais – considerando principalmente descritores que representam a forma da imagem (Xue et al. 2011)(Antani et al. 2004). Uma ferramenta chamada SPIRS, desenvolvida para a Web, também trabalha com comparação de ROIs em imagens de Raio-X da coluna vertebral e tem obtido bons resultados (Hsu et al. 2009a).

Na Tabela 4 estão listados alguns dos sistemas CBIR específicos para a área médica, com suas respectivas modalidades e domínio de doenças no qual atuam. Há na literatura numerosos protótipos de sistemas que implementam algoritmos de reconhecimento avançado

de objetos para a detecção de determinados órgãos e estruturas, tanto em nível anatômico quanto em nível de doenças e funcional (Zhou et al. 2008). No entanto, as metodologias de análise de imagem existentes não são genéricas o suficiente para lidar com os diferentes órgãos diretamente ou com imagens cuja modalidade esteja fora do domínio da aplicação original.

Tabela 4: Alguns dos Sistemas CBIR para área médica e suas especialidades

Tecnologia	Modalidade da Imagem	Domínio Específico	Sistema
Raio X	RX – Tradicional	Mama	(Korn et al. 1998) (Giger 2002) (Rosa et al. 2002)
		Espinha	CBIR2 - (Antani et al. 2002) (Medina et al. 2012)
	Tomografia Computadorizada	Pulmão	ASSERT - (Shyu et al. 1999) BRISC - (Lam et al. 2007) (Liu et al. 2001)
		Cérebro	MIMS – (Chbeir et al. 2000)(Seshadri et al. 2003) (Yanxi Liu Dellaert 1998)
Ressonância Magnética	RM Tradicional	Cérebro	(Chu et al. 1998) ILive - (Gomes & Mojsilovic 2002)
		Espinha	(Kumaran & Bhavani 2012)
	RM Funcional	Cérebro	(Bai et al. 2007)
Sem modalidade específica			SPIRS - (Hsu et al. 2009b) IRMA – (Lehmann et al. 2006) I2C - (Chronaki et al. 1997) KMed - (Chu 1995) MedGift - (Müller et al. 2005) CBMIR - (Willy & Kufer 2004)

Buscando a generalização dos sistemas e a viabilização desses em ambientes reais de aplicação, alguns trabalhos têm sido desenvolvidos no sentido de agregar funcionalidades de CBIR aos PACS (Fischer, Deserno, et al. 2008)(Tan et al. 2006)(Azevedo-Marques et al. 2005). Todos esses trabalhos de agregação têm por objetivo fazer com que os PACS deem suporte a uma recuperação eficiente de imagens, de forma totalmente digital e automática. Porém, conseguir essa recuperação eficiente no domínio médico é um trabalho bastante árduo. Isso porque características importantes das imagens médicas encontram-se normalmente em regiões localizadas e não na imagem como um todo. Essa dificuldade tem feito com que os sistemas de consulta sejam voltados para áreas específicas, como nos exemplos acima, e que também esses dependam de algum tipo de anotação ou interação com o usuário.

Em (Rosa et al. 2002) é apresentado um sistema CBIR, denominado SRIS-HC (Sistema de Recuperação de Imagens Similares do Hospital das Clínicas). Nesse sistema duas técnicas de extração de características de imagens foram adotadas, são elas: o histograma

tradicional e o histograma métrico, descrito com detalhes em (Traina et al. 2003). Com esses descritores, características da distribuição dos níveis de cinza (intensidade dos pixels) foram utilizadas como características de comparação. A intersecção entre os histogramas foi utilizada como medida de dissimilaridade. Outra proposta de integração de CBIR em PACS é apresentada em (Lehmann et al. 2003), onde o sistema IRMA (*Image Retrieval in Medical Applications*), aperfeiçoado mais recentemente (Deserno et al. 2012)(Deserno et al. 2008)(Lehmann et al. 2006), traz também a possibilidade de se classificar imagens de acordo com a modalidade, orientação e região do corpo ou sistema biológico, através de consultas aos vizinhos mais próximos. Em (Tan et al. 2006) é apresentado um sistema CBIR integrado ao PACS e ao RIS. Nele são utilizadas características locais de textura em imagens de pulmão originadas de CT de alta-resolução. Aqui, estudos de casos armazenados no RIS são recuperados utilizando as imagens do PACS como objetos de consulta.

Todos esses trabalhos de integração de funcionalidade CBIR em sistemas PACS têm uma visão promissora no campo do diagnóstico auxiliado por computador, no incentivo à prática da medicina baseada em casos na radiologia e no próprio ensino e treinamento de novos médicos radiologistas (Datta et al. 2008). Essa visão de aproximar a tecnologia da informação ao ambiente de análise de imagens radiológicas sem causar grande impacto na rotina habitual do médico é o grande objetivo da construção de sistemas mais eficientes. A evolução dessas ferramentas CBIR em ambientes práticos vem crescendo fortemente nos últimos anos. A aproximação e interação das características visuais extraídas por esses sistemas de recuperação de imagens por conteúdo com a percepção do usuário médico, vista como essencial para a sua aceitação em ambientes reais (Jaimes et al. 2006), vem se tornando aos poucos evidente nos trabalhos de processamento de imagens médicas (Pietrzyk et al. 2008)(Donovana et al. 2008), bem como em estudos sobre a satisfação do usuário com os sistemas CBIR (Filardi & Traina 2008), demonstrando assim a forte tendência de aproximação do sistema ao usuário final, o médico radiologista (Ponciano-Silva et al. 2009).

Sistema Higiia

Durante a realização deste trabalho de doutorado, foi desenvolvido pelo aluno com colaboração de colegas do GBdI uma ferramenta CBIR para realização das pesquisas em ambiente real (Bedo et al. 2012). A ferramenta integra diversos módulos já desenvolvidos pelo grupo, são eles: o SIREN/Arboretum (Barioni et al. 2006), o MedFMI-SIR (Kaster et al. 2011) e uma biblioteca de extratores de características de imagens e funções de distância (Bedo 2013). Além das funcionalidades de extração de características e consultas por

similaridade oferecidas pelos módulos integrados no sistema, o aluno desenvolveu uma interface gráfica capaz de aproximar o uso do sistema na prática clínica. As principais funcionalidades foram:

- visualização de imagens, agora com ferramentas de *zoom* e janelamento (incluídas na última versão),
- visualização e emissão de laudos/classificação das imagens,
- visualização das imagens retornadas como similares, com possibilidade de ênfase nas imagens apontadas como relevantes e eliminação das imagens apontadas como irrelevantes,
- realimentação por relevância utilizando o algoritmo originalmente proposto por Rocchio (J J Rocchio 1971) e, por fim, incluído na última versão,
- uma ferramenta de sugestão diagnóstica com base na classe majoritária das imagens tidas como similar à de referência a ser diagnosticada.

Com ele foi possível realizar experimentos práticos em Ambiente Real no HC-FMRP para avaliar todas as propostas defendidas nesta tese. O Sistema Higiia está em constante evolução, adaptando-se aos principais módulos e algoritmos desenvolvidos pelo grupo de pesquisa no qual o aluno que defende esta tese está inserido. Em trabalhos futuros, além das evoluções propostas nesta tese, serão incluídas novas funcionalidades e algoritmos recentemente desenvolvidos por alunos do grupo de pesquisa, como por exemplo, acompanhamento de perfis de usuários (Bugatti et al. 2014) e consultas por diversidade (Santos 2012).

Desafios em CBIR

O ser humano é muito eficiente no reconhecimento de informação apresentada de maneira gráfica, e, portanto, tem uma grande facilidade em interpretar imagens. A tecnologia disponível atualmente para a construção de sistemas computacionais que analisem imagens digitalizadas e delas recuperem alguma informação é ainda muito incipiente, quando comparada com essa capacidade do ser humano. Isso origina uma separação muito grande entre o que um indivíduo pode reconhecer em uma imagem, e o que pode ser esperado de um processo computacional que tente reproduzir esse reconhecimento. Essa separação origina o que se convencionou chamar de “descontinuidade semântica” (*semantic gap*).

Analisando os algoritmos para CBIR e os sistemas protótipo contidos na literatura, percebe-se que o uso desta tecnologia em aplicações reais durante a rotina clínica é muito limitado. A descontinuidade semântica tem sido apontada como a principal causa dessa

limitação, porém, estudos mostram que há outros problemas na área de CBIR que devem também ser considerados (Welter et al. 2011)(Antani et al. 2008).

A descontinuidade de conteúdo (*content gap*) é um deles, onde a habilidade do sistema em representar o entendimento humano a partir das características extraídas das imagens é colocada à prova. O usuário especialista, principalmente os médicos, deseja não só estabelecer um padrão de comparação de acordo com seu próprio conceito de similaridade, mas também conhecer quais são as características extraídas e o que cada uma delas representa na imagem. No caso das imagens médicas, o conceito de similaridade durante a prática clínica é muito instável, podendo ser mudado de uma consulta para outra (de um contexto para outro). Isso porque a percepção humana também considera informações associadas à experiência e as informações subjetivas do caso clínico estudado. Essa peculiaridade exige dos sistemas CBIR mecanismos que possibilitem estender as dimensões sobre as quais as características são extraídas. Por exemplo, grau de detalhe, análise multiescala, uso de informação temporal, entre outras. A falta desses mecanismos de ajustes das características nos sistemas atuais é o que a literatura nomeia de descontinuidade de características (*features gap*) (Deserno et al. 2009).

Há também problemas relacionados à praticidade da implementação do sistema CBIR. Um deles, a descontinuidade no desempenho (*performance gap*), diz respeito à performance de resposta às consultas por similaridade (Traina et al. 2009). A descontinuidade no desempenho avalia o uso de técnicas de indexação de imagens e a integração dessa tecnologia à infraestrutura médica disponível no ambiente. Outra preocupação no desenvolvimento de sistemas CBIR faz referência à interação com o usuário final, ou seja, a forma como se disponibilizam os parâmetros e as diferentes consultas possíveis de serem realizadas pelos médicos, bem como a possibilidade de combinação das características disponíveis. Essa descontinuidade na usabilidade do sistema (*usability gap*) também considera a clareza na resposta de cada consulta, avaliando o quanto há de auxílio para o entendimento das saídas do sistema e as possibilidades de refinamento da consulta.

Avaliação de Sistemas CBIR com o usuário

Muitos dos desafios descritos nos parágrafos anteriores somente serão realmente medidos se houver uma avaliação maciça de sistemas CBIR no ambiente clínico real. É na prática que critérios de usabilidade, performance, conteúdo e até semântico podem ser mensurados com maior clareza. Há na literatura poucas propostas e tentativas de avaliação e análise de sistemas CBIR na prática clínica. Alguns estudos comparam aspectos técnicos de

sistemas CBIR, observando como cada sistema aborda os diferentes *gaps* existentes na área de recuperação de imagens médicas (Depeursinge et al. 2011), porém não exploram a interação com o usuário. Foi encontrado um trabalho que, apesar de antigo, apresenta uma proposta de avaliação com interatividade do usuário, observando as modificações de diagnóstico de imagens de pulmão com e sem a apresentação de imagens similares (Marchiori et al. 2001). Porém, a avaliação apresentada nesse último trabalho não modela com precisão o processo de diagnóstico convencional, além de não apresentar interatividade para realimentação por relevância. No entanto, os resultados apresentados por ele, somados à uma pesquisa recente sobre modelo de qualidade em CBIR (Souza 2012), justificam uma investigação mais aprofundada do tema, pois ainda há muito a se fazer para quantificar a capacidade dos sistemas CBIR em influenciar a decisão e/ou certeza do especialista no diagnóstico. A falta de estudo prático adequado, abordando o impacto do CBIR no ambiente clínico real, pode aumentar a desconfiança dos especialistas nesse tipo de sistema e ainda desmotivar e desacelerar o avanço dessas ferramentas como meio de auxílio ao diagnóstico. Por isso foi de preocupação do idealizador desta pesquisa propor a metodologia apresentada no Capítulo 7.

3.5 Técnicas para diminuir a Descontinuidade Semântica (*Semantic Gap*)

Um dos problemas mais estudados e mencionados na literatura é a descontinuidade semântica, tida como a divergência existente entre a resposta do sistema computacional e aquela esperada pelo especialista. O tratamento desse problema é muito importante e tem impulsionado diversos centros de pesquisa a desenvolverem técnicas focadas em caracterizar a semântica existente nos contextos de imagens gerais (Zhang et al. 2013)(Chen et al. 2013) e imagens médicas (Zhou et al. 2008) (Jin et al. 2007).

Explorando o espaço perceptual

Alguns trabalhos têm buscado encontrar relacionamentos entre as características intrínsecas de baixo e médio nível das imagens e suas avaliações semânticas e subjetivas fornecidas pelos usuários (Samala et al. 2009) (Rorissa et al. 2008) (Barb et al. 2005). Esse último trabalho desenvolveu um *framework* para gerenciar conteúdos visuais de patologias pulmonares. Esse *framework*, chamado ESSENCE (*Evolutionary System for Semantic Exchange of Information in Collaborative Environments*), disponibiliza métodos semânticos para descrever anomalias visuais, aproveitando para coletar conhecimento no domínio

médico. Ele divide sua atuação em três domínios. O semântico (avaliação feita pelos médicos), o das características (números extraídos das imagens por algoritmos de extração de características) e o domínio das preferências do usuário. Porém, esse trabalho busca encontrar o relacionamento entre as características extraídas e a semântica médica considerando o poder que as características têm em prever a doença/lesão em questão. Um exemplo seria avaliar quanto determinadas características podem ser utilizadas para prever a existência de formatos espiculados em nódulos de pulmão.

Outras abordagens buscam encontrar esse relacionamento semântico através de uma avaliação do quão próximo essas características conseguem simular a noção de similaridade da percepção humana. Um exemplo é apresentado em (Muramatsu et al. 2008), que utilizou uma Rede Neural Artificial (RNA) para buscar relação entre as características intrínsecas das imagens mamográficas e as avaliações dos radiologistas. Essas avaliações foram realizadas de modo subjetivo, onde 10 (dez) radiologistas agruparam 200 pares de imagens com microcalcificações de acordo com a similaridade de cada um. Valores médios de similaridade foram obtidos através das avaliações e utilizados como dados para ensino e treinamento de uma rede neural artificial. Essa, por sua vez, depois de treinada, passou a atuar como uma medida de similaridade psicofísica. Com esse algoritmo de medida de similaridade baseado em uma RNA treinada com avaliações humanas, Muramatsu (Muramatsu et al. 2008) buscou determinar medidas de similaridade que pontuavam o relacionamento entre as características subjetivas descritas pelos radiologistas, como por exemplo o BI-RADS (*Breast Imaging Reporting And Data System*) e as características objetivas extraídas computacionalmente das imagens.

Não há na literatura muitos estudos para investigar a correlação entre os resultados de CBIR e a percepção de semelhança dos radiologistas em imagens pulmonares. Em (Li et al. 2003) são apresentadas medidas de similaridade psicofísicas para distinção de nódulos malignos e benignos em tomografia computadorizada de tórax. Em (Kim et al. 2010) encontramos uma investigação sobre o relacionamento entre o CBIR e a semântica de similaridade em imagens de pulmão e em (Liu et al. 2007) uma coletânea de trabalhos em CBIR genéricos que incluem semânticas de alto nível.

Ontologia

O uso de ontologias como tentativa de diminuição da descontinuidade semântica em sistemas CBIR também tem sido objeto de estudo em alguns grupos (Coustaty et al. 2011)(Deserno et al. 2009)(Zhou et al. 2008). Essa abordagem pode ser definida como uma

especificação explícita abstrata e simplificada (conceitualização) de um domínio a ser representado. Ela é definida como a interpretação estruturada dos conceitos mais relevantes em um determinado domínio. O termo explícito significa que o conjunto de conceitos utilizados e as restrições e relacionamentos a ele aplicados são previamente definidas e formalizadas. Essa abordagem proporciona ao computador a capacidade de processá-las sem a necessidade de definições em linguagem natural. Ela descreve um conhecimento consensual e representa-o através de relacionamentos e axiomas formados por um conjunto não vazio de atributos, conceitos e especificações.

Realimentação Por Relevância

Figura 12: Processos onde atua o uso de Técnicas de Realimentação por Relevância

Uma técnica comprovadamente eficiente para reformulação de consultas por similaridade e, conseqüentemente, para aumento da precisão das respostas de um sistema CBIR é a Realimentação de Relevância (*Relevance Feedback* - RF)(Li & Allinson 2013)(Azevedo-Marques & Rangayyan 2013). Essa técnica refere-se a uma interação cíclica onde o usuário seleciona um pequeno conjunto de imagens, que para ele são relevantes à consulta, e o sistema então as utiliza para revisar a consulta original. Essa revisão é baseada nas características derivadas dessas imagens relevantes selecionadas. A consulta revisada é então executada e um novo conjunto de imagens é obtido. Existem várias abordagens possíveis para a RF, as mais comuns são:

- *Alteração do Centro de Consulta*, que procura estimar um ponto ideal de referência para a busca no espaço métrico estabelecido, aproximando-se dos exemplos considerados adequados e afastando-se daqueles considerados inadequados;
- *Ajuste de Pesos*, que trabalha com o aumento do valor de ponderação (importância)

das características que auxiliam na recuperação de imagens similares e a diminuição do valor de ponderação das características que dificultam este processo;

- *Aprendizado por Exemplo*, que utiliza modelos de inteligência artificial (redes neurais artificiais, árvores de decisão e sistemas especialistas, entre outros) para inserir a experiência (resposta) do usuário no processo de realimentação;

Diversos trabalhos têm procurado aprimorar técnicas de realimentação por relevância buscando uma aproximação entre o resultado obtido pelo sistema e aquele esperado pelo usuário (Santos et al. 2008) (Paredes et al. 2008). A Tabela 5 resume algumas das principais técnicas utilizadas para realização de realimentação por relevância e, imaginando todo o processo de consulta por similaridade, na Figura 12 são apontadas as etapas desse processo onde a realimentação atua, incluindo, indiretamente, conhecimento intrínseco da percepção do especialista.

Tabela 5: Descrição Resumida das principais técnicas de Realimentação por Relevância

	Nome	Descrição	Referência
Alteração do Centro de Consulta	Técnica de Rocchio	Estratégia de movimentação de um único centro de consulta baseada na rotulação (e/ou ponderação) das imagens resultantes. Ela busca minimizar a diferença entre o centro de consulta e as imagens rotuladas como relevantes e maximizar a diferença entre as irrelevantes.	(J. J. Rocchio 1971) (Ye et al. 2010)
	Expansão da Consulta	É uma abordagem baseada em múltiplos centros. Ela separa as imagens rotuladas como relevantes em diferentes grupos. Cada agrupamento é representado pela imagem mais próxima ao centro original. As imagens representativas de cada grupo são utilizadas como centros de consulta. As sub-consultas são ponderadas de acordo com as respectivas distâncias entre o objeto original e o representante do grupo.	(Nguyen et al. 2012)
	QCluster	Metodologia semelhante à Expansão da Consulta porém utiliza um método de agrupamento adaptativo para classificar e fundir agrupamentos semelhantes, além de determinar contornos arbitrários com relação à abrangência de cada sub-consulta.	(Nguyen et al. 2012)
	Top-K	Nessa abordagem, as imagens rotuladas como relevantes são consideradas como novos centros de consulta. Nela, as consultas aos múltiplos centros são executadas individualmente e os resultados são combinados com o intuito de melhorar o desempenho da recuperação.	(Wang et al. 2013) (French et al. 2004)
Ajuste de Pesos	Desvio Padrão	Pondera as dimensões do vetor de características com base no inverso do desvio padrão dos valores de cada dimensão das imagens rotuladas como relevantes. Quanto maior o desvio padrão, menor a importância da dimensão analisada.	(Guldogan & Gabbouj 2009)
	Query Scaling	Utiliza uma medida de similaridade (<i>normalized cross-correlation</i>) entre as imagens rotuladas como relevantes e a imagem de consulta para parametrizar e ponderar as dimensões dos vetores de características.	(Xu 2010) (Doulamis & Doulamis 2006)

Aprendizado por Exemplo	Support Vector Machines	Abordagem que procura definir um hiper-plano separador entre as imagens rotuladas como relevantes e as irrelevantes. Esse hiperplano é definido com base na maximização da distância entre ele e o vetor mais próximo de cada classe.	(Wang et al. 2014)
	Classificador Bayesiano	Aprendizado Probabilístico baseado no Teorema de Bayes. O método procura prever o quanto cada imagem é desejada pelo usuário a partir de um histórico de interações do usuário.	(Kalpana & Krishnamoorthy 2012)

Recuperação por Texto e Conteúdo

Tradicionalmente, a recuperação de imagens era feita através de comparação de textos/valores numéricos contidos nas anotações e/ou legendas das imagens armazenadas na base. Apesar de ser um método maduro e bem consolidado, essa recuperação baseada em texto é limitada devido a problemas relacionados à disponibilidade e qualidade das informações associadas às imagens (Alexandrini et al. 2005), além de não ser escalável com o aumento da quantidade de imagens adquiridas diariamente em hospitais e centros clínicos.

Os avanços na área de Visão Computacional proporcionaram o surgimento de métodos de consulta por similaridade que utilizam a própria imagem como parâmetro na consulta. No entanto, o sucesso dessas técnicas puramente baseadas em conteúdo, quando aplicada a um conjunto diverso de imagens clínicas, também vem apresentando limitações relativas à percepção semântica. No entanto, trabalhos recentes mostraram que uma combinação de técnicas de recuperação de imagens baseada em texto e baseada em conteúdo pode conseguir um melhor desempenho na recuperação de imagens médicas, quando combinados de forma eficaz (Névéol et al. 2009). Nessa linha, os pesquisadores têm se empenhado em desenvolver técnicas de anotação automática para incluir a semântica relacionada a cada imagem armazenada. É o caso da técnica apresentada em (Kalpathy-Cramer & Hersh 2010), que utiliza atributos visuais das imagens para marcá-las de forma automática. Essas anotações passam a fazer parte do processo de indexação e são utilizadas como atributos textuais capazes de filtrar ou reordenar os resultados durante o processo de recuperação. Esses atributos textuais, nesse caso, são divididos em três categorias: modalidade da imagem, localização anatômica e descrição patológica encontrada na imagem.

3.6 Métodos de Avaliação

A maioria dos sistemas CBIR é projetada para recuperar imagens similares tendo uma imagem exemplo como centro de referência. Para avaliar o desempenho desses sistemas,

normalmente se constroem bases de imagens pré-classificadas de acordo com um determinado padrão de normalidade e considera-se que as imagens da mesma classe são as mais semelhantes entre si. Assim como as curvas ROC (*Receiver Operating Characteristic*), que medem a sensibilidade e especificidade da classificação dos dados são usadas para avaliar desempenho de sistemas de auxílio ao diagnóstico, um dos métodos mais utilizados para a avaliação de eficiência de sistemas de busca é o gráfico de precisão e revocação (Alto et al. 2005) (Müller et al. 2004). Nessa metodologia, considera-se que para uma determinada consulta por similaridade exista um conjunto R de imagens relevantes e um conjunto A de objetos recuperados. A intersecção desses dois conjuntos ($R \cap A$) compreende os elementos relevantes que foram recuperados pela consulta realizada. A Figura 13 ilustra a disposição desses conjuntos. A partir desses conjuntos as medidas de precisão e revocação podem ser obtidas da seguinte maneira:

- - Revocação é a porção do conjunto de elementos relevantes (R) que foram recuperados na consulta dentre todos os relevantes recuperados ($R \cap A$):

$$Revocação = \frac{(R \cap A)}{R}$$
- - Precisão é a porção do conjunto de elementos relevantes recuperados ($R \cap A$) dentre todos os que foram recuperados na consulta (A): $Precisão = \frac{(R \cap A)}{A}$

Figura 13: Ilustração: Exemplo de distribuição de conjuntos de imagens para cálculo de precisão vs. revocação

Para uma avaliação mais abrangente e confiável dos resultados obtidos por um determinado sistema de recuperação de imagens similares, deve-se estabelecer um conjunto de dados apropriado para avaliação e assim realizar diversas operações de consultas, atribuindo a cada uma delas um elemento diferente da base como centro de referência. Com as medidas de desempenho dessas diversas consultas é possível construir um gráfico de precisão vs. revocação, como ilustrado na Figura 14, onde cada ponto do gráfico representa a média aritmética dos desempenhos dessas diversas consultas. A partir do gráfico, a análise do

desempenho geral do sistema se resume em analisar o formato e altura da curva obtida, sendo que, quanto mais próxima do topo do gráfico a curva estiver, melhor é o resultado das operações de busca. Analisando o gráfico apresentado na figura acima, é fácil perceber que o Método 2 apresentou melhor desempenho que o Método 1.

Figura 14: Exemplo de gráfico de precisão vs. revocação

Nessa avaliação por precisão e revocação, apenas um padrão de semelhança (o relativo à classificação realizada) é avaliado de fato, o que torna o método muito próximo de uma avaliação de classificação. Essa metodologia, apesar de bastante utilizada, tem apresentado algumas limitações de interpretação devido ao fato de engessar a avaliação em um padrão de classificação (e não de similaridade propriamente dita). A eficiência de sistemas CBIR deve ser medida considerando o quão realmente semelhantes são as imagens retornadas pelo sistema (e não apenas se são ou não da mesma classe). A interação humana é uma ferramenta valiosa para avaliar o desempenho de um sistema CBIR, porém, essa avaliação é muito subjetiva, sendo altamente dependente do conceito de similaridade do observador. Propostas recentes vêm sendo desenvolvidas nesse sentido, onde a avaliação leva em consideração o relacionamento entre as características extraídas das imagens e as características visuais percebidas pelo usuário (Rorissa et al. 2008) e a noção de similaridade dos próprios usuários (Penatti & Torres 2010). Nesse último trabalho, o autor propôs uma ferramenta chamada Eva, que avalia diferentes descritores segundo a perspectiva dos usuários. Nessa avaliação, a ferramenta disponibiliza uma lista contendo uma composição das 30 imagens mais similares de cada descritor (eliminando as duplicadas). A lista final é embaralhada (mantendo-se a referência ao(s) descritor(es) e posição em que estavam) e apresentada ao usuário, que por sua vez indica as imagens que ele considera mais semelhantes à imagem de consulta. O processo é repetido até que todas as imagens de consulta sejam avaliadas. Ao fim do processo a ferramenta oferece medidas de eficácia que representam valores de precisão de acordo com a perspectiva de similaridade indicada pelo

usuário.

3.7 Considerações Finais

Neste capítulo foram apresentados os conceitos e metodologias relacionados às etapas essenciais de um sistema CBIR. Nele foram apresentados alguns sistemas que compõem o estado da arte bem como os principais desafios relacionados ao tema. Em sua parte final o capítulo abordou algumas técnicas propostas para diminuir a descontinuidade semântica existente nos sistemas atuais bem como uma visão geral sobre as formas de avaliação desses sistemas.

O principal objetivo dos trabalhos relacionados à recuperação de imagens por conteúdo é melhorar as respostas às consultas por similaridade e atacar diretamente o problema da divergência entre o que o sistema computacional diz que é similar e o que o especialista espera que o sistema responda como sendo similar (descontinuidade semântica). Nessa busca pela eficácia é muito importante considerar o contexto onde o sistema está inserido. No caso das imagens médicas, o fator crítico a ser considerado na recuperação por conteúdo é a existência ou não de patologias e as alterações visuais que essas acarretam nas imagens. Essas alterações ocorrem, normalmente, em partes pequenas ou detalhes das imagens, fazendo com que sistemas globais não alcancem um bom resultado por considerarem a maior parte da imagem como semelhante. No próximo capítulo serão abordados conceitos relacionados ao campo de aplicação da pesquisa e tese proposta nesse trabalho.

Capítulo 4 - Percepção do Especialista para Consultas por Similaridade em Imagens Médicas

4.1 Considerações Iniciais

Neste capítulo são apresentados conceitos relacionados à percepção do radiologista durante análise e comparação de imagens. São abordados conceitos gerais de similaridade e do processo de análise humana no diagnóstico por imagens. Por fim são apresentados padrões levantados dentre os radiologistas, encontrados em imagens de mama, pulmão e coluna e utilizados neste trabalho. Todas as definições apresentadas servem de base para a proposta de Sistematização para sistemas CBIR perceptuais, e sua aplicabilidade em ambientes reais de diagnóstico por imagem.

4.2 Conceitos de Similaridade para Recuperação de Imagens por Conteúdo

Ao se trabalhar com recuperação de imagens por conteúdo a partir de uma imagem exemplo, um conceito fundamental é a definição do que significa “similaridade” ou semelhança. Dois objetos são similares quando apresentam características visuais muito parecidas. Mas quem define quais características visuais são mais ou menos parecidas? O julgamento de similaridade é bastante subjetivo e altamente dependente do usuário, principalmente na análise de imagens médicas (Hadjiiski et al. 2012).

O ser humano é muito eficiente no reconhecimento visual de informações, e, portanto, tem uma grande facilidade em interpretar imagens. Quando comparada com essa capacidade do ser humano a tecnologia disponível atualmente para a construção de sistemas computacionais que analisem imagens e delas recuperem alguma informação é tida ainda como muito incipiente. Porém, há na literatura um esforço para formalização de modelos de similaridade que procuram abstrair o processo da determinação da similaridade realizado pelo ser humano (Wangenheim & Wangenheim 2003), facilitando assim uma reprodução computacional. As suposições assumidas nesses modelos seguem as seguintes propriedades:

- **Reflexividade:** Um objeto é similar a ele mesmo.
- **Simetria:** Se um objeto A é similar a B, então o objeto B é similar a A.

- **Transitividade:** Se o objeto A é similar a B e o objeto B é similar a C, então A também é similar a C.
- **Monotonicidade:** A similaridade de dois objetos cresce monotonicamente com o aumento de correspondências e a redução de diferenças.

No entanto, em situações reais de comparações e similaridade as propriedades de Monotonicidade e Transitividade se mostram amplamente rejeitadas na literatura (Burkhard 2004). Um exemplo trivial seria a comparação entre o Homem, o Centauro e o Cavalo, ilustrado na Figura 15. A transitividade nesse exemplo foi invalidada porque “subjetivamente” o critério de semelhança foi substituído. Ou seja, as partes da imagem comparadas na situação 1 (Homem e Centauro) são diferentes das partes comparadas na situação 2 (Centauro e Cavalo). Nesse exemplo, bem como na maioria dos casos reais de comparação humana, essa subjetividade faz com que a transitividade e, consequentemente a desigualdade triangular, não sejam satisfeitas.

Figura 15: Exemplo da não transitividade em comparação de imagens (Felipe 2005)

A outra rejeição é relativa à monotonicidade. Nesse caso, a variação de um atributo (por exemplo: forma) em uma unidade não produz a mesma alteração de dissimilaridade visual que a mesma variação em outro atributo (por exemplo: tamanho). Um exemplo prático para essa rejeição foi o resultado da tese de doutorado de (Felipe 2005), onde o autor defende que para recuperação de imagens médicas, há atributos que mantêm uma interação forte com a alteração de similaridade, ou seja, uma pequena variação nesses atributos gera uma diferença de similaridade muito grande. Em contrapartida, há também outros atributos cuja interação é tida como fraca, onde uma grande variação em seu valor não provocaria na imagem uma variação perceptual muito grande. Porém, novamente percebe-se que o principal motivo dessa rejeição para a monotonicidade foi, tal como na transitividade, a substituição “subjetiva” do critério de semelhança durante uma mesma comparação (Felipe et al. 2009).

Essa subjetividade no conceito de similaridade vem atraindo a atenção de pesquisadores principalmente para aplicações radiológicas, onde se encontram evidências de que a noção de semelhança visual é altamente subjetiva (Nishikawa et al. 2004). Muitos trabalhos buscam captar essa noção subjetiva de similaridade através da interatividade com o usuário do sistema, alguns utilizando a Realimentação por Relevância para captar a noção de similaridade (percepção) dos médicos (Wu & Yap 2007), outros na definição de perfis de usuários (Bugatti et al. 2014)(Tsikrika et al. 2012)(Hoi & Lyu 2004). Além da realimentação por relevância, alguns trabalhos utilizam de pareamento/ordenação visual e manual de conjuntos de imagens buscando assim modelar os conceitos de similaridade para tais conjuntos (Tourassi et al. 2013)(Xu et al. 2012)(Kumazawa et al. 2008). No entanto, todos esses trabalhos de captação da noção de similaridade conseguem melhores resultados definindo/especificando o critério de similaridade a ser utilizado na definição de similaridade. Assim, percebe-se a grande necessidade da formalização e do estabelecimento desses critérios como pré-requisito para diminuição da lacuna semântica e construção de um CBIR Perceptual, tal como proposto nessa tese.

4.3 Processo de análise humana no diagnóstico por Imagem (Semiologia Radiológica)

É importante conhecer o processo humano de análise no diagnóstico por imagem para, com esse processo, conseguir formalizar um modelo que considere essa percepção médica na construção de sistemas CBIR (Sedghi et al. 2012).

Na prática clínica, os exames radiológicos mais comuns são: Raio X (RX), Tomografia Computadorizada (CT) e Ressonância Magnética (RM). Cada um desses exames gera imagens digitais no padrão DICOM, porém, os princípios físicos e computacionais de formação dessas imagens são muito distintos. Esses princípios físicos trazem consigo uma semântica, e a informação sobre determinadas características de cada tecido representado na imagem. Uma descrição resumida desses exames pode ser lida na Tabela 6. Devido a essa diferença na semântica expressa pelos níveis de cinza das imagens, a comparação entre imagens de diferentes modalidades (para recuperação por conteúdo) passa a não fazer tanto sentido semântico, a não ser que as diferenças sejam previamente levadas em consideração no processo de comparação.

Além do princípio físico de formação da imagem, durante o curso de graduação, os futuros médicos aprendem a semântica contida nos diversos exames radiológicos. Também

conhecida como "Semiologia Radiológica", esse aprendizado engloba o uso de terminologias para descrição de lesões (achados radiológicos) e suas explicações fisiopatológicas. Um exemplo de terminologias relativas à densidade do tecido examinado é apresentado na Tabela 7. Outras terminologias bastante utilizadas estão relacionadas a contornos (regular/irregular), formas (esférica/triangular) e medidas (micro/macro), todas relacionadas a características visuais apresentadas pelas lesões nas imagens.

Tabela 6: Descrição Resumida dos principais exames radiológicos

	Descrição do Método	Descrição da Imagem
RX- Tradicional	Formada pela captação de radiação X que atravessa as diferentes áreas anatômicas do corpo. Esses raios são atenuados pelos tecidos de acordo com suas propriedades, estrutura e densidade. O sinal transpassado é captado por uma película fotográfica (no caso de filme) ou processados por sistemas computacionais (no caso de radiologia digital).	Produce uma imagem bidimensional, onde as estruturas do corpo estão sobrepostas no plano.
CT	Apesar de utilizar do mesmo princípio físico de formação da imagem do RX, há também um processo de reconstrução computacional dos dados obtidos. Esses dados são oriundos de varreduras sucessivas de uma mesma região por um feixe de radiação X, com alterações sucessivas das posições relativas feixe/objeto.	Gera uma imagem tridimensional, formada por fatias bidimensionais contendo cortes do objeto, com uma melhor qualidade da imagem nos diversos planos
RM	Obtidas por princípios físicos diferentes da radiação. A análise convencional dessas imagens é baseada no sinal proveniente de cada região, derivado do tempo de relaxação longitudinal (T1) e transversal (T2) das diversas substâncias que compõem os tecidos orgânicos e a densidade de prótons de cada região. A diferença de sinais captada quando os tecidos são submetidos a um campo magnético é o que diferencia o contraste entre as regiões de uma imagem.	Gera uma imagem tridimensional, formada por fatias bidimensionais contendo cortes do objeto que serve para avaliação qualitativa e quantitativa (através da quantificação do sinal)

Tabela 7: Algumas Terminologias utilizadas em exames de RX e CT

Tecnologia	Tecido	Terminologia	Descrição Visual
Raio-X	Ar	Radio transparente	Produce cor preta
	Gordura	Radio transparente	Produce cor cinza escuro
	Água	Hipotransparente	Produce cor cinza claro
	Osso	Radiopaco	Produce cor branca
	Metal	Radiopaco	Produce cor branca
Tomografia Computadorizada	Ar	Hipodensa	Produce cor preta
	Gordura	Hipodensa	Produce cor cinza escuro
	Osso (calcificação)	Hiperdensa	Produce cor branca
	Algumas lesões	Isodensa	Mesma densidade do tecido normal que o circunda

Como forma de padronizar, de maneira bem geral, a análise do radiologista, os especialistas dizem que, durante uma análise da imagem para laudo do exame, é importante procurar por:

- Deslocamento da estrutura normal
- Aumento de tamanho relativo à estrutura normal
- Presença de densidades/sinais/brilho anormais
- Destruição da estrutura normal ou bordas

Todos esses critérios de busca envolvem características relacionadas à forma, tamanho, densidade/sinal/brilho, bordas e contornos de estruturas presentes nas imagens. É sabido que alguns desses critérios exigem um maior tempo de análise que outros, devido a alterações mais sutis na imagem. Esses normalmente são os casos que geram maiores dúvidas entre os radiologistas e, por isso, há na literatura diversos trabalhos envolvendo sistemas de reconhecimento e classificação de lesões desse tipo (Depeursinge et al. 2008)(Abe et al. 2004).

O fato interessante na análise humana de imagens médicas é o de que mesmo com essa padronização geral, para cada situação diagnóstica, o radiologista, de modo subjetivo e particular, considera algumas características visuais com maior relevância que outras (Hadjiiski et al. 2012). Essa subjetividade está relacionada com a formação, a experiência e a suspeita diagnóstica do médico radiologista (Alexandre & Tavares 2007). No entanto, quanto mais específica for a avaliação menor será a variação intra e inter observador (Kumazawa et al. 2008), reforçando a necessidade de modelos computacionais que permitam uma especificação do escopo durante a comparação de imagens. Uma proposta nessa direção será apresentada no Capítulo 5 desta tese.

4.4 Estabelecimento de Domínios Específicos

Para se contornar a descontinuidade semântica e perceptual na análise de imagens médicas é razoável pensar na definição de critérios de similaridade para diferentes conjuntos de dados (Malik & Baharudin 2013). Embora ainda não existam processos adequados para a definição e identificação de critérios de similaridade (além do arcabouço defendido nessa tese), já existem processos que permitem extrair dados significativos para a busca por similaridade em domínios de imagens restritos (Tao et al. 2007)(Xue et al. 2007). Nesses trabalhos o contexto e os critérios de similaridade são definidos de forma manual durante a criação da base de testes a ser consultada (utilizando uma base bem específica ao contexto analisado). Porém, para que o conceito de CBIR possa ser utilizado em situações clínicas reais, é necessário tornar possível a definição e posterior identificação automatizada de critérios de similaridade nos quais as imagens possam ser submetidas. Assim, o CBIR poderá ser utilizado em domínios menos específicos, abrindo-se a possibilidade de alcançar uma análise automatizada que não apresente uma descontinuidade semântica muito grande em relação à capacidade de análise dos usuários humanos (Pietrzyk et al. 2008)(Jaimes et al. 2006). Para aplicação da sistematização apresentada no Capítulo 5, são tomados por base os domínios específicos

descritos a seguir.

4.4.1 Massa e Calcificação em Regiões de Interesse de Mamografias

Tabela 8: Exemplos de achados em Mamografia

Achado	Descrição Fisiopatológica	Descrição Visual	Exemplo
Massa	- Proliferação irregular de células tomando espaço do tecido normal	- Descrições de Forma e Contorno conforme descritas na Figura 16.
Calcificação	Presença de Tecido com excesso de concentração de cálcio	- Pontos pequenos e brilhantes - Com distribuição: Agrupada, Linear ou Dispersa - Apresentando formas definidas como: Puntiforme, Granulada, Esférica, Linear ou Amorfa

Figura 16: Variações de formas e contornos em nódulos de mama

As imagens de mama, na verdade, de regiões de interesse (ROIs), foram extraídas de exames de mamografias coletados de uma base de imagens de domínio público, a DDSM³. Essas continham dois tipos diferentes de achados radiológicos. São eles: Massa e Calcificação, conforme descrito na Tabela 8. Nesse tipo de imagem há padrões visuais melhor estabelecidos e formalizados. A utilização do padrão de registro BI-RADS (*Breast Imaging Reporting and Data System*) ajuda na classificação dos achados em mamografias de acordo com as variações das formas, contornos e distribuição. Por exemplo: De acordo com os

³ <http://marathon.csee.usf.edu/Mammography/Database.html>

radiologistas, tumores malignos geralmente infiltram o tecido adjacente, resultando em um contorno irregular, espiculações, margens anguladas e irregulares. Essas são características que indicam malignidade. Por outro lado, massas de limites precisos, arredondados ou ovalados tem maior probabilidade de serem lesões benignas.

4.4.2 Lesões Pulmonares Difusas em CT de Tórax

Tabela 9: Exemplos de achados em CT de pulmão

Achado	Descrição Fisiopatológica	Descrição Visual	Exemplo
Enfisema	Aumento permanente do espaço aéreo distal ao bronquíolo terminal, acompanhado de destruição das paredes alveolares. Região focal de baixa atenuação, usualmente sem paredes definidas	<ul style="list-style-type: none"> - região mais escura (bolha escura) - sem contornos visíveis - distribuição não-uniforme
Consolidação	É a substituição do ar alveolar por transudato, exudato ou tecido. Aumento homogêneo da atenuação do parênquima pulmonar	<ul style="list-style-type: none"> - manchas claras - distribuição homogênea - contorno escuro nas margens dos vasos e nas paredes das vias aéreas
Espessamento do septo Interlobular	Opacidade linear fina que corresponde ao septo interlobular. Aumento na espessura do septo interlobular, usualmente causado por edema, infiltração celular ou fibrose	<ul style="list-style-type: none"> - aumento da espessura do septo interlobular - Opacidade linear fina (linha fina e mais clara) - Contorno pode ser liso, irregular ou nodular
Faveolamento (favo de mel)	Cistos pulmonares de destruição fibrosados, simbolizando perda completa da arquitetura acinar e bronquiolar. Espaços císticos agrupados, caracterizados por paredes bem definidas, geralmente espessas	<ul style="list-style-type: none"> - Espaços císticos agrupados - Usualmente com diâmetros comparáveis. Varia de 0,3 a 1 cm - Contornos bem definidas e geralmente espessos - Estrutura similar a um favo de mel
Vidro Fosco	Aumento da atenuação pulmonar, sem obscurecer as margens brônquicas e vasculares, causado por preenchimento parcial do espaço aéreo, espessamento intersticial ou colapso parcial alveolar (entre outros)	<ul style="list-style-type: none"> - regiões mais claras - distribuição não homogênea e não concentrada - sem contorno nas margens dos Vasos e vias aéreas - apresenta espessamento intersticial

São vários achados clínicos que podem ser encontrados em imagens de pulmão, porém, para os trabalhos desenvolvidos e apresentados aqui, trata-se apenas de uma gama

disponibilizada pelo Hospital das Clínicas de Ribeirão Preto. A Tabela 9 apresenta os achados contidos nas imagens repassadas pelo hospital e resume suas características fisiopatológicas, bem como as alterações visuais que esses achados causam nas imagens de pulmão, conforme descrições encontradas em (Souza-Jr et al. 2002).

4.4.3 Lesões por Compressão Vertebral em Imagens de RM da Coluna

As imagens de Ressonância Magnética, também disponibilizadas pelo Hospital, são de coluna vertebral e estão divididas entre normais e portadoras de fraturas originadas por lesões malignas ou benignas, de acordo com doenças como osteoporose ou câncer de coluna. Há na literatura diversos achados radiológicos utilizados como preditores significativos para diferenciação de lesões benignas e malignas dentro do escopo de Fraturas por Compressão Vertebral (VCF – *Vertebral Compression Fractures*) (Thawait et al. 2013). A Tabela 10 apresenta um conjunto de padrões visuais significativos, utilizados como critério de similaridade para diferenciar algumas fraturas por compressão vertebral.

Tabela 10: Exemplos de achados em CT de pulmão

Achado	Descrição Fisiopatológica	Características Visuais	Exemplo
Deformidade do Corpo Vertebral	- Enfraquecimento do osso trabecular dos corpos vertebrais e consequente compressão desses corpos vertebrais a medida que o osso trabecular se impacta contra si mesmo	- Achatamento proporcional (anterior = posterior) - Diminuição da “Altura” da Vértebra
		- Achatamento da Placa Terminal Superior - Não afeta o Platô (Placa Terminal) Inferior - Alteração na Forma da Vértebra
		- Achatamento da Placa Terminal Inferior - Não afeta o Platô (Placa Terminal) Superior - Alteração na Forma da Vértebra
Presença de Sinal Vertebral	- Substituição da gordura do Corpo Vertebral por Edema	- Mudança na cor do Corpo Vertebral - O Edema traz diminuição do sinal, a gordura é brilhante, já o Edema é opaco - Distribuição Homogênea (Podendo ser superior, inferior ou equilibrada)
		- Mudança na cor do Corpo Vertebral - Distribuição Difusa

4.5 Considerações Finais

Os conceitos de similaridade no processo de comparação e análise humana que o especialista no domínio de imagens utiliza no processo de geração de diagnóstico por imagem apresentados neste capítulo ajudaram na identificação das etapas de especificação de contexto para análise de imagens em sistemas CBIR Perceptuais (apresentados no Capítulo 5). Além disso, os aspectos visuais relevantes identificados nas imagens de coluna foram importantes para estabelecer indicadores visuais considerados na construção de extratores específicos ao contexto (apresentados no Capítulo 6). Com esse conhecimento foi possível estabelecer critérios gerais para comparação de imagens de pulmão, mama e coluna vertebral utilizados como casos para os estudos desenvolvidos neste trabalho.

Capítulo 5 – Sistematização da Percepção Médica na Construção de Sistemas CBIR

5.1 Considerações Iniciais

Uma avaliação recente de vários sistemas CBIR para radiologia chegou à seguinte conclusão: *“O uso de contextos muito específicos na formulação de ferramentas CBIR não permite a transferência do sistema para outros domínios na prática clínica. O futuro das ferramentas CBIR e sua aplicação como ferramentas CAD, depende de arquiteturas mais genéricas, além de princípios e interfaces para apoiar a criação rápida de protótipos para aplicação em outros domínios médicos”* (Depeursinge et al. 2011). Essa conclusão procede, pois a discussão embasada pela Seção 4.2 mostrou que a definição de um critério de similaridade em um determinado julgamento tem um papel essencial na avaliação da similaridade. Porém a formalização desse critério no processo de comparação de imagens não é explorado na construção de sistemas CBIR tradicionais. Na literatura estudada, não foi encontrada uma padronização para o estabelecimento de critérios de similaridade. Nos trabalhos encontrados e analisados, o contexto de busca, e consequentemente os critérios de similaridade, é definido durante a criação da base de testes (utilizando uma base bem específica ao contexto analisado). Essa abordagem tradicional limita o uso desses sistemas em ambientes reais, onde uma série de imagens diferentes (geradas por protocolos distintos) são armazenadas utilizando-se dos Sistemas PACS.

Além do exposto acima, os métodos e sistemas CBIR encontrados apresentaram opções de descritores para um contexto específico, apontando um deles como o mais representativo para o conjunto de imagens delimitado. Essa decisão indica o melhor resultado considerando gráficos de precisão durante processo de classificação de imagens, que é baseado na existência ou não de determinada doença na imagem. Essa abordagem parte do princípio de que “imagens de mesma classe são sempre semelhantes entre si”. Porém, no Capítulo 4 é mostrado que mesmo em domínios específicos, uma mesma doença pode apresentar vários “achados” radiológicos com características visuais distintas, trazendo uma noção clara de que poderá haver diferentes “melhores descritores” para cada característica visual (achado) desenvolvida por determinada doença, situação já comprovada em (Ponciano-

Silva et al. 2009). A presença desses padrões exige uma especificação ainda maior nos critérios de comparação estabelecidos para consultas por similaridade. Assim, a solução para se contornar essa situação delicada é a definição de critérios de similaridade para diferentes subconjuntos de um mesmo conjunto de dados.

No entanto, os argumentos apresentados nos dois parágrafos anteriores colocam os sistemas CBIR de diante um grande paradoxo. Como especificar ainda mais o contexto de comparação das imagens, para assim diminuir o gap semântico dos sistemas CBIR e, ao mesmo tempo, tornar o Sistema CBIR apto para um ambiente real, que seja mais genérico? Ou seja, onde é preciso uma generalização da aplicação para tratamento das diferentes imagens geradas a todo o momento pelos exames radiológicos? Neste capítulo é apresentada uma solução para esse paradoxo. Neste capítulo é proposta uma nova abordagem para a sistematização de critérios de similaridade, que é decomposta e descrita de maneira a permitir o suporte à busca por conteúdo em diferentes níveis de especificidade. Traduzindo esses conceitos para a prática de consultas por similaridade, este capítulo apresenta arcabouço teórico que padroniza diferentes níveis de especificidade para definição e identificação de Critérios de Similaridade e a inclusão de Parâmetros de Percepção durante a comparação de imagens médicas em sistemas CBIR.

5.2 Representação de Conteúdo Intrínseco em Imagens Médicas

Conforme descrito na Seção 2.2, a extração de características é realizada por técnicas de processamento de imagens seguida de uma análise detalhada de seus níveis de cinza. É essa representação numérica que mapeia as características visuais da imagem e as tornam passíveis de uma comparação por similaridade com menor custo computacional. A classificação/hierarquização em níveis de representação de conteúdo mostrada na Seção 3.2 exemplifica o nível 1 de representação de Busca por Conteúdo com uma consulta baseada em imagem exemplo (ou referência). Os outros dois níveis propostos utilizam consultas baseadas na semântica do conteúdo da imagem. Porém, pela observação e experiência dos médicos da área, as aplicações CBIR para imagens médicas visando auxílio ao diagnóstico serão quase sempre baseadas em imagem exemplo, o que forçaria todos os diferentes tipos de consulta por conteúdo para auxílio a diagnóstico serem classificadas apenas no nível 1 proposto.

5.2.1 Proposta de Hierarquização de Extratores de Características

Nessas condições, a literatura da área ainda não traz uma divisão formal e consolidada

dos diferentes níveis de consulta utilizando imagens médicas como exemplo. Com isso, como parte da sistematização da inclusão da percepção do especialista na construção de sistemas CBIR para área médica, a seguinte classificação é aqui proposta:

Nível 1 - Consultas por similaridade baseadas em características primitivas, consideradas na literatura como tradicionais, representadas por descritores que modelam estímulos visuais primários. Nesse nível de consulta não há preocupação com qualquer tipo de semântica envolvida nos princípios físicos de formação da imagem. Nem mesmo o envolvimento da semântica contida nos pixels da imagem, tratando a imagem médica como uma imagem equivalente às imagens encontradas na Web. Um exemplo de consulta desse tipo seria: “Recupere imagens similares a essa imagem de referência”. Esse tipo de consulta utiliza características de cor e textura, como as descritas na Seção 2.2.2, bem como características gerais de forma, como Momentos de Zernike, onde não há necessidade de segmentação específica para representação de características visuais de forma dos objetos contidos na imagem.

Nível 2 - Consultas por similaridade realizadas com base em características primitivas associadas à semântica relacionada ao contexto onde a imagem de consulta está inserida. Nesse nível de consulta há uma preocupação em incluir informações do contexto durante a extração das características. Isso envolve o tipo de imagem comparada (por exemplo, se é imagem de RX, CT ou RM), inclusive a semântica de cada pixel concernente ao processo físico de formação da imagem, bem como características relacionadas à região de interesse na comparação. Nesse nível já não faz mais sentido comparar imagens de RX com imagens de CT, ou ainda, comparar imagens de CT de tórax com CT de abdômen. Um exemplo de consulta desse tipo seria: “Recupere imagens de pulmão semelhante a essa imagem referência”, ou ainda “Recupere imagens com tamanho e aspecto do cerebelo similar ao dessa imagem de consulta”. Esse tipo de consulta utiliza características de cor, forma e textura, como as descritas na Seção 2.2.2, associadas a pré-processamentos específicos do contexto (como descritos na Seção 2.2.1) e/ou a segmentação e reconhecimento de estruturas específicas, conforme Seções 2.2.3 e 2.2.4.

Nível 3 - Consultas por similaridade por meio de características abstratas, envolvendo raciocínio complexo na interpretação da região de interesse. Normalmente essas características estão relacionadas à semântica de manifestação de doenças possíveis de ser

expressa na região comparada. Nesse nível de consulta são consideradas não somente informações específicas de um contexto inicial, mas também informações mais subjetivas ao usuário. Um exemplo de consulta desse tipo seria: “Recupere imagens com quantidade de ar no pulmão similar ao dessa imagem de referência” ou ainda “Recupere imagens onde o pulmão seja similar ao da imagem de referência, observando a presença de espessamento e de regiões radiopacas (mais escuras) e homogêneas”. Esse tipo de consulta pode utilizar características de cor, forma e textura, porém, sempre associadas à semântica de alto nível da lesão/doença/achado. Por exemplo: “O que significa ou como representar a quantidade de ar ou a presença de espessamento no pulmão em termos de características extraídas da imagem?”. Esse tipo de consulta exige uma aproximação maior com o usuário final do sistema. Isso porque são eles os que definem quais são as características visuais condizentes com cada achado radiológico ou o conteúdo semântico de cada estrutura relevante para identificação de uma determinada doença. A Tabela 11 resume a hierarquia proposta:

Tabela 11: Descrição Resumida da Hierarquia proposta para Representação de Conteúdo Visual em Imagens Médicas

	Descrição da Hierarquia	Exemplos de Características
Nível 1	Uso de características primitivas (cor e textura) da imagem como um todo, sem definição de contexto ou regiões específicas. <i>“Recupere imagens iguais a essa de referência”</i>	Histogramas, Características de Haralick, Gabor, Momentos de Zernick entre outros
Nível 2	Uso de características primitivas (cor, forma e textura) associadas a um contexto bem definido, onde a imagem de consulta está inserida. <i>“Recupere imagens cuja coluna seja semelhante ao dessa de referência”</i>	As mesmas descritas para o nível 1, associadas a regiões específicas e bem definidas de interesse.
Nível 3	Uso de características abstratas, com inferência complexa relacionada à semântica de manifestação de cada doença possível de ser expressa na região comparada. <i>“Recupere imagens cuja quantidade de ar no pulmão seja igual ao dessa de referência”</i>	Densidade da Mama, Quantidade de Ar no Pulmão, Proporcionalidade entre alturas de Corpos Vertebrais, entre outros

5.2.2 Discussão sobre a adequação da proposta

Muitos sistemas CBIR oferecem recursos apenas para o **Nível 1** e isso pode justificar a dificuldade desses sistemas em alcançar um alto grau de satisfação entre os usuários. As características primitivas extraídas das imagens, sem qualquer especificação de contexto, têm um poder bastante limitado na representação dos aspectos visuais quando comparado à riqueza de interpretação do ser humano (Smeulders et al. 2000). Já o **Nível 2** de consultas pode ser encontrado em aplicações mais específicas. Por exemplo, em (Balan et al. 2007), onde, após a segmentação das estruturas de interesse (no caso, massa branca, massa cinzenta e caixa craniana do cérebro humano) foram computadas medidas para representação de cada região. São elas: centro de massa ou centróide, massa (ou tamanho) e nível de cinza médio.

Deve-se notar que essas características estão relacionadas à cor e forma das imagens segmentadas e com isso essas informações ficam associadas à semântica específica do contexto onde estão inseridas. Há poucos trabalhos na literatura que trabalham com o tipo de consulta do **Nível 3**. Em (Ponciano-Silva et al. 2009) há um detalhamento de aproximação do CBIR com o usuário final e a definição das características visuais condizentes com a manifestação de lesões intersticiais de pulmão, onde foram extraídas características relacionadas à quantidade de ar, distribuição intersticial e quantidade de tecidos densos dentro do pulmão. Outros trabalhos que utilizam características nesse nível podem ser encontrados em (Medina et al. 2012).

Em (Bugatti et al. 2009) é realizada uma comparação entre extratores que se encaixam nesses três níveis de consultas por similaridade em imagens médicas. Nesse trabalho o uso de características relacionadas a consultas do Nível 3 mostraram um ótimo desempenho comparado à extratores tradicionais (do nível 1) na representação de lesões pulmonares, utilizando menos características (vetor de características menor) que as representações do nível 1 e 2. Além disso, esse trabalho mostrou que a combinação de características dos níveis 2 e 3 foi a que demonstrou melhor eficiência na representação no domínio estudado.

Com base nos estudos realizados na literatura, percebe-se que os trabalhos realizados com extratores do Nível 1 de consultas ajudam a consolidar técnicas de extração de características primitivas, porém, a aplicabilidade em ambientes reais se mostra bastante limitada. Percebe-se também que há um número crescente de trabalhos focados na implementação de extratores do Nível 2 e que essa área tem trazido bastante contribuição para a consolidação desses sistemas na prática clínica. Além disso, apesar dos poucos trabalhos explorando extratores do Nível 3, essa vertente tem se tornado muito promissora para aplicações médicas visto o aumento do interesse dos pesquisadores médicos em contribuir com o desenvolvimento de técnicas mais específicas visando o auxílio ao diagnóstico em domínios bem específicos.

5.3 Definição de “Critérios de Similaridade” para Comparação de Imagens Médicas

Ao se desenvolver qualquer extrator de características para CBMIR, principalmente aqueles relacionados aos Níveis 2 e 3 de representação de conteúdo intrínseco, é bastante importante especificar/formalizar em quais contextos esses extratores poderão ser utilizados. Para facilitar a compreensão desses contextos, esta seção propõe a padronização de níveis

hierárquicos de “Critérios de Similaridade” e formaliza a definição e utilização desses critérios. Uma visão geral é ilustrada na Figura 17 e as definições são formalizadas a seguir.

Figura 17: Visão Geral em níveis para definição de Critérios Similaridade em imagens médicas

5.3.1 Proposta de Hierarquização de Critérios de Similaridade para Imagens Médicas

Nível I – Definições do Exame: Esse nível considera as informações do exame e método de geração da imagem. Partindo da existência de vários tipos e protocolos de aquisição de imagens radiológicas (p.ex.: RX de Tórax, CT do Tórax, Mamografia, RM Axial do Encéfalo, etc), define-se um conjunto de informações representativas de cada tipo de exame e seus respectivos protocolos de aquisição e geração da imagem que devem ser satisfeitas como pré-requisito para comparação

entre características de duas imagens. Essas definições se encaixam no escopo do primeiro nível de definição dos Critérios de Similaridade.

Nível II – Definição de Regiões de Interesse: Esse nível considera as informações da imagem a ser comparada. Cada imagem, mesmo aquelas do mesmo exame, dispõe de uma ou várias regiões de interesse. Essa definição de qual(is) região(ões) de interesse estarão envolvidas na comparação entre duas imagens se encaixam no segundo nível de definição dos Critérios de Similaridade.

Nível III – Definição de Conceitos Semânticos: Esse nível engloba a definição de conceitos abstratos que envolvem a sensação de percepção visual (ou semântica) humana durante o processo de comparação de duas imagens de um mesmo contexto. Para cada “Contexto de Análise”, há diferentes aspectos visuais que podem ser considerados e/ou combinados pelo usuário durante a análise (p.ex.: distribuição/alterações de cor, clareamento/escurecimento de determinada estrutura, alterações de forma, alterações de distribuição/textura do tecido ou de estruturas na imagem). Essa definição de qual(is) aspecto(s) visual(is) estará(ão) envolvido(s) na comparação entre duas imagens se encaixam no Nível 3 de definições dos Critérios de Similaridade.

Definidos os critérios de cada nível de Similaridade, uma série de possíveis algoritmos de processamento e análise de imagens disponíveis na literatura poderão modelar cada aspecto visual estabelecido por eles. Esses algoritmos representarão cada aspecto visual através de vetores de características (ou assinaturas) e, a comparação de similaridade entre esses vetores será realizada por uma Função de Distância. A definição do par <Extrator de Características, Função de Distância> é conhecido na literatura como “Descritor de Similaridade”, ou apenas Descritor. Assim, cada descritor (ou seja, um par <Extrator de Características, Função de Distância>, do nível da Aplicação) irá modelar com melhor propriedade e eficiência algum (ou alguns) aspecto visual (ou semântico, de nível conceitual). A ligação (ou ponte) entre o Nível da Aplicação e o Nível Conceitual Semântico será realizada pela definição do conceito de “Parâmetros de Percepção”.

5.3.2 Formalização dos Critérios de Similaridade

Conforme descrito nas Seções 2.2 e 3.3, há na literatura diversos extratores de características e funções de distâncias que podem ser utilizados para representação e comparação de padrões visuais em imagens para recuperação por conteúdo. No entanto, a

simples criação do código não é suficiente para incluí-lo em um sistema CBMIR completo, visando aplicação em ambiente real. Essa inclusão depende do estabelecimento de pré-requisitos (critérios dos níveis I a III de similaridade) que as imagens deverão cumprir para se qualificarem para serem submetidas a cada método de comparação implementado. No entanto, como estabelecer um padrão para criação e inserção desses métodos na construção de Sistemas CBMIR Perceptual?

Nível de Aplicação

Definindo E um conjunto de extratores de características (simples ou compostos):

$$E = \{e_1, e_2, \dots, e_n\}$$

e M um conjunto de métricas (Funções de Distância simples ou compostas):

$$M = \{m_1, m_2, \dots, m_n\},$$

ambos disponíveis na literatura. Pode-se estabelecer a seguinte definição:

Definição: “*Descritor de Similaridade*” – é um conjunto formado por um ou mais pares <extrator, função de distância> capazes de representar um conjunto de imagens, gerando um espaço que permita noção de similaridade entre as imagens representadas.

Assim, um dado conjunto S de possíveis “Descritores de Similaridade” (simples ou compostos) será formado pelas diversas combinações possíveis entre os elementos do conjunto E e M :

$$S = \{s_1, s_2, \dots, s_n\}, \text{ com } s_k = \{e_i, m_j\} \text{ ou } s_{kc} = \{s_i, s_j\}$$

onde m_j é a Função de Distância que apresenta melhor eficácia na representação de similaridade da característica visual representada por e_i e s_{kc} representa um descritor composto pela combinação de múltiplos descritores.

Nível Conceitual I de Definição de Critérios de Similaridade

No ambiente real de geração de imagens médicas há diversos tipos de exames radiológicos, cada um com diversos protocolos de geração de imagens possíveis de serem realizados. Esse conjunto de diferentes protocolos de geração de imagens médicas pode ser definido como:

$$P = \{p_1, p_2, \dots, p_n\},$$

onde P é o conjunto de protocolos de exames de geração de imagens radiológicas disponíveis no ambiente de aplicação e p_i é um protocolo específico, como, por exemplo, “RX de Tórax”

ou “Mamografia”.

Nível Conceitual II de Definição de Critérios de Similaridade

As imagens geradas por determinado protocolo de exame poderão ser analisadas em diferentes “Contextos de Análise”, devido à presença de uma ou várias “Regiões de Interesse” passíveis de análise naquele tipo de imagem.

Definição: “*Contexto de Análise*” – é um conjunto formado por um par <protocolo do exame, região de interesse> capaz de determinar um escopo de análise específico, gerando uma definição que permita identificar os pré-requisitos de análise daquele contexto específico.

Assim, o “Contexto de Análise” passa a ser uma combinação de um determinado elemento do conjunto P com uma ou várias das diversas regiões de interesse possíveis de serem analisadas nas imagens geradas por aquele tipo de exame. Ou seja,

$$C = \{c_1, c_2, \dots, c_n\}, \text{ com } c_k = \{p_i, r_j\},$$

onde r_j é a definição de uma ou várias regiões de interesse a ser analisada nas imagens geradas pelo protocolo p_i .

Nível Conceitual III de Definição de Critérios de Similaridade

Cada “Contexto” pode ser analisado na perspectiva de diferentes aspectos semânticos presentes na região a ser analisada. Esses aspectos são determinados pelos próprios especialistas do contexto e devem ser expressos por “Palavras-Chaves”. Essa palavra-chave sumariza de modo claro o aspecto semântico definido pelo especialista do contexto (por exemplo: “Quantidade de Ar no Pulmão”). Assim, para cada contexto de análise poderá haver um ou mais aspecto visual/semântico passível de ser modelado para posterior comparação e consultas por similaridade.

Ligação entre Nível Conceitual e Nível de Aplicação

Com as padronizações/definições acima, pode-se agora formalizar o conceito de “Parâmetros de Percepção”. Cada aspecto visual dos diferentes níveis conceituais dos critérios de similaridade pode ser expresso por uma “palavra-chave” que define de modo sucinto a sensação de percepção humana durante o processo de comparação de duas imagens em um mesmo contexto. No caso do Nível III de definição de Critérios de similaridade, onde

já se levantou uma palavra-chave para descrever um aspecto semântico específico do contexto, essa mesma palavra-chave deverá ser utilizada como descritor da percepção naquele contexto.

A “palavra-chave” que sumariza o aspecto visual será um dos elementos que irá compor o que denominamos de “Parâmetro de Percepção”. A importância desse elemento está na possibilidade de mapeamento do melhor descritor de similaridade – s_i (representação de baixo nível do aspecto visual intrínseco da imagem) – para cada aspecto visual de alto nível relevante da imagem no contexto especificado. Assim, o “Parâmetro de Percepção” é definido como se segue:

Definição: “*Parâmetro de Percepção*” – composição de uma palavra-chave que represente semanticamente uma característica visual de alto nível, determinada pelo especialista, e o Descritor de Similaridade que melhor modele numericamente o espaço de similaridade causado pela percepção da característica visual representada.

Seja Ac_i o conjunto de Parâmetros de Percepção descritos pelos especialistas de determinado contexto c_i :

$$Ac_i = \{a_1, a_2, \dots, a_n\}, \text{ onde } a_j \rightarrow s_i$$

cada parâmetro a_i conterá uma palavra chave que:

- na interface de interação do usuário com o sistema (alto nível) ele servirá de parâmetro de entrada (escolhido pelo usuário, junto com a imagem exemplo) para a realização da consulta e expressará de forma sucinta a sensação de percepção humana a ser utilizada no processo de comparação das imagens.
- no nível da aplicação (baixo nível) mapeará o melhor descritor de similaridade $s_i \in S$, responsável por representar o conteúdo intrínseco da imagem relativo ao aspecto visual expresso pelo parâmetro.

Definição de Critérios de Similaridade

Definir critérios de similaridade para buscas por conteúdo em imagens médicas nada mais é do que especificar, de forma padronizada, qual deve ser o contexto da comparação para determinada imagem e quais serão os parâmetros de percepção considerados nas

possíveis consultas por similaridade.

5.3.3 Definição do melhor descritor de similaridade para cada parâmetro de percepção

A abordagem utilizada pela maioria dos trabalhos da área escolhe um melhor descritor de similaridade para todas as imagens da base de um determinado contexto (Abordagem Tradicional). Essa escolha se baseia na precisão média de cada descritor disponível na aplicação para aquele contexto, obtida através de alguma Função de Avaliação (p.ex. Área abaixo do gráfico de Precisão e Revocação, algoritmo Classificador IBL, curvas ROC, entre outras). No entanto, nas seções anteriores foi demonstrado que cada contexto pode ser analisado na perspectiva de diferentes aspectos visuais. Assim, cada “Parâmetro de Percepção” estabelecido pelo especialista do contexto atua como uma condição de contorno que delimita um subconjunto de imagens dentro do conjunto todo. Para cada subconjunto poderá haver um descritor de similaridade específico que melhor o diferencie dos demais subconjuntos. O Algoritmo 1 propõe uma maneira de se estabelecer, para cada subconjunto definido pelo parâmetro de percepção, o melhor descritor de similaridade que o represente.

Algoritmo 1 Define, com base em uma função de avaliação de desempenho, qual o melhor descritor (<extrator, função distância>) para um determinado parâmetro de percepção.

Entrada: Parâmetro de Percepção *ppID*, Contexto *contexto*, Base de Teste do Contexto *D[]*.

01: obterListaDeExtratores(in: *contexto*, out: *listaDeExtratoresCompatíveisComContexto*)

02: *aux* = 0;

03: **para** *listaDeExtratoresCompatíveisComContexto* **faça**

04: | obterMetricas (in: *extrator_i*, out: *listaDeMétricasCompatíveisComExtrator*)

05: | **para** *listaDeMetricasCompatíveis* **faça**

06: | | executarFunçãoAvaliação(in: *extrator_i*, in: *metrica_j*, in: *D[]*, out: *desempenho*)

07: | | **se** *aux* < *desempenho* **então**

08: | | | *descritor* = id(*extrator_i*, *metrica_j*);

09: | | **fim se**

10: | **fim para**

11: **fim para**

12: inserirDescritor(in: *contexto*, in: *ppID*, in: *descritor*);

As informações de quais parâmetros de percepção estão disponíveis para cada contexto e, qual descritor de similaridade melhor representa cada parâmetro são armazenadas em uma tabela do sistema. No momento de cada consulta, o sistema recupera essas informações oferecendo ao usuário uma lista de opções de parâmetros de percepção para

realização da consulta.

5.3.4 Estudo de Caso Prático: Imagens de Mama

Buscando medir a influência da escolha do melhor descritor de similaridade para determinado contexto, considerando um único descritor para todo o contexto (Metodologia Tradicional) versus a escolha do melhor descritor para cada parâmetro de percepção levantando no contexto (Metodologia Proposta), esse estudo de caso prático foi preparado objetivando comparar essas duas abordagens.

O conjunto de imagens utilizado nesse experimento é formada por 2892 imagens de regiões de interesse (ROIS), extraídas de exames de mamografia disponibilizados por uma base de imagens de domínio público, a DDSM⁴. Para esse experimento será considerada a lesão (Massa ou Calcificação) bem como o tipo da lesão (maligna ou benigna) como critérios de classificação das imagens. Portanto, a base foram considerados quatro classes: Massa Maligna, Massa Benigna, Calcificação Maligna, Calcificação Benigna.

Para esse estudo de caso, foram utilizadas as seguintes definições:

- Protocolo do exame radiológico: $p = \text{“Mamografia”}$
- Contexto focado na análise de Região de Interesse: $c_I = \{ \text{“Mamografia”}, \text{“ROI”} \}$
- Aspectos semânticos estabelecidos de acordo com as classes encontradas na base, ou seja: $\{ \text{“Suspeita de Massa Maligna”}, \text{“Suspeita de Massa Benigna”}, \text{“Suspeita de Calcificação Maligna”}, \text{“Suspeita de Calcificação Benigna”} \}$
- Conjunto de Extratores disponíveis para esse contexto:
 $E = \{ \text{Histograma}, \text{Haralick}, \text{Wavelets de Haar}, \text{Wavelets de Daubechies} \}$
- Conjunto de Funções de Distância disponíveis para esse contexto:
 $M = \{ L_1, L_2, L_{inf}, \text{Divergência de Jeffrey (DJ)}, \text{Canberra (CA)} \}$

Aplicando a metodologia proposta (Algoritmo 1), com uma função de Avaliação de desempenho baseado na abordagem de validação cruzada (*10-folds cross validation*) utilizando o algoritmo de classificação IBL1 sobre a base, obtém-se o resultado demonstrado na Tabela 12. Analisando os valores de precisão apresentados de cada par <extrator, função de distância>, a metodologia utilizada mostrou que os seguintes descritores apresentaram melhores resultados para cada aspecto semântico estabelecido, possibilitando assim a configuração dos parâmetros de percepção a serem utilizados no contexto:

$$Ac_I = \{ a_1, a_2, a_3, a_4 \} \text{ onde:}$$

⁴ <http://marathon.csee.usf.edu/Mammography/Database.html>

- a_1 = “Suspeita de Calcificação Benigna” $\rightarrow s_1 = \{\text{Histograma}, L_{\text{inf}}\}$
- a_2 = “Suspeita de Calcificação Maligna” $\rightarrow s_2 = \{\text{Histograma}, \text{Divergência de Jeffrey}\}$
- a_3 = “Suspeita de Massa Benigna” $\rightarrow s_3 = \{\text{Wavelet de Haar}, L_1\}$
- a_4 = “Suspeita de Massa Maligna” $\rightarrow s_4 = \{\text{Wavelet Daubechies}, \text{Divergência de Jeffrey}\}$

Tabela 12: Precisão Média para cada Parâmetro de Percepção

Par. Percep	L_1	L_2	L_{inf}	CA	DJ	Extratores
Calcificação Benigna	61%	65%	71%	51%	50%	Histograma
	59%	59%	59%	59%	60%	Haralick
	55%	60%	60%	64%	60%	Wavelet H.
	58%	56%	61%	59%	54%	Wavelet D.
Calcificação Maligna	56%	56%	54%	70%	75%	Histograma
	52%	50%	53%	55%	50%	Haralick
	59%	58%	57%	62%	61%	Wavelet H.
	60%	60%	60%	58%	58%	Wavelet D.
Massa Benigna	61%	65%	64%	52%	51%	Histograma
	57%	52%	56%	50%	55%	Haralick
	66%	60%	56%	57%	54%	Wavelet H.
	50%	51%	50%	51%	50%	Wavelet D.
Massa Maligna	64%	59%	52%	65%	60%	Histograma
	61%	60%	64%	64%	51%	Haralick
	61%	62%	64%	57%	65%	Wavelet H.
	77%	75%	68%	79%	85%	Wavelet D.

É importante ressaltar que a “ausência de parâmetro de percepção” significa utilizar a metodologia tradicional já consolidada na literatura para determinação do melhor descritor de similaridade. Os trabalhos da área utilizam a precisão média considerando a base toda (e não a precisão para cada subconjunto separadamente). A Tabela 13, a seguir, apresenta os resultados (precisão média) de cada descritor utilizando a metodologia tradicional.

Tabela 13: Precisão Média da base toda (sem Parâmetro de Percepção)

Extratores	L_1	L_2	L_{inf}	CA	DJ
Histograma	60.5%	61.25%	60.25%	59.50%	59.00%
Haralick	57.25%	55.25%	58.00%	57.00%	54.00%
Wavelet H.	60.25%	60.00%	59.25%	60.00%	60.00%
Wavelet D.	61.25%	60.50%	59.75%	61.75%	61.75%

Conforme os resultados obtidos pela aplicação da metodologia tradicional, apresentados na Tabela 13, o melhor Descritor de Similaridade passa a ser a Wavelet de Daubechies com a função de distância Canberra:

- Ausência de Parâmetro de Percepção $\rightarrow s_5 = \{\text{Wavelet Daubechies, Canberra}\}$

Uma comparação dos resultados obtidos pelas duas metodologias pode ser visto na Tabela 14.

Tabela 14: Comparação de Resultados

Parâmetro de Percepção	Metodologia Proposta		Metodologia Tradicional	
	Descritor Utilizado	Precisão	Descritor Utilizado	Precisão
Calcificação Benigna	$s_1 = \{\text{Histograma, } L_{inf}\}$	71%	$s_5 = \{\text{Wavelet Daubechies, Canberra}\}$	59%
Calcificação Maligna	$s_2 = \{\text{Histograma, DJ}\}$	75%		58%
Massa Benigna	$s_3 = \{\text{Wavelet de Haar, } L_1\}$	66%		51%
Massa Maligna	$s_4 = \{\text{Wavelet Daubechies, DJ}\}$	85%		79%
	Precisão Média	74.25%	Precisão Média	61.75%

Com esse resultado fica evidente que a não utilização da sistematização proposta e defendida nessa tese, faz com que a eficiência de CBIR diminua consideravelmente. Analisando a perda de precisão para cada Parâmetro de Percepção estabelecido, de acordo com a Tabela 14, a perda seria de 71% para 59% no caso de imagens com suspeita de Calcificação Benigna, de 75% para 58% no caso de imagens com suspeita de Calcificação Maligna, de 66% para 51% no caso da Massa Benigna e de 85% para 79% no caso de Massa Maligna. Tais perdas demonstram claramente a necessidade de se considerar a sistematização proposta.

5.3.5 Estudo de Caso Teórico: Definição de Vários Contextos

Nesse estudo de caso foram separados três tipos diferentes de exames radiológicos. São eles:

- $p_1 = \text{"Mamografia"}$
- $p_2 = \text{"CT de Torax"}$
- $p_3 = \text{"RM da Coluna Vertebral"}$

Com esses três protocolos de exames coletados e/ou disponibilizados pelo HC-FMRP, foram definidos os seguintes "Contextos de Análise":

- $c_1 = \{p_1, \text{"ROI"}\}$

- $c_2 = \{ p_2, \text{"Pulmão Segmentado"} \}$
- $c_3 = \{ p_2, \text{"ROIs 30x30 do interior do pulmão"} \}$
- $c_4 = \{ p_3, \text{"Imagem Completa"} \}$
- $c_5 = \{ p_3, \text{"Vértebras da Coluna Lombar"} \}$
- $c_6 = \{ p_3, \text{"Corpos Vertebrais Segmentados"} \}$

Dessa forma, dada uma imagem de consulta de CT de Tórax, por exemplo, o especialista terá auxílio do sistema em dois tipos de análise distintos. Um considerando características visuais do pulmão completo (toda extensão pulmonar) e outra considerando uma pequena região de interesse no interior do pulmão. Ficará a critério do radiologista escolher qual o contexto de análise que se adequará à suspeita diagnóstica levantada por ele.

Além disso, para cada contexto bem definido, há a possibilidade de se estabelecer diferentes Aspectos Visuais ou Semânticos para cada um dos contextos. Nesse estudo de caso foi adotado o seguinte:

- No C_1 são: {“Textura”},
- no C_2 e o C_3 são: {“Proporção de Ar”, “Escurecimento de Estruturas”, “Espessamento”},
- no C_4 são: {“Distribuição de Cor”, “Presença de Fratura Óssea”},
- no C_5 e o C_6 são: {“Deformidade no Corpo Vertebral”, “Presença de Sinal Vertebral”}.

É importante ressaltar que dentre os aspectos estabelecidos acima, há alguns que são visuais (como Textura, Distribuição de Cor entre outros) e há aqueles que são semânticos (como no caso da Proporção de Ar ou Espessamento). Nota-se também que há descrições de aspectos visuais/semânticos comuns a diferentes contextos (como é o exemplo do C_5 e C_6). Isso é correto e comum de acontecer pois são contextos que, apesar de distintos, trabalham com o mesmo tipo de imagem/estrutura do corpo. O sentido semântico da expressão (ou “Palavra-Chave”) nos dois contextos são iguais, porém, ao ser mapeada ao descritor, cada expressão irá compor diferentes parâmetros de percepção (como poderá ser constatado na composição dos Parâmetros de Percepção abaixo).

Para composição dos Parâmetros de Percepção é importante saber quais os algoritmos de extração e comparação de imagens estão disponíveis no sistema. O Sistema CBIR nesse estudo de caso teórico foi aplicado com os seguintes extratores e funções de distância:

- Conjunto de Extratores disponíveis para esse contexto:

$E = \{\text{Histograma, Haralick, BulkExtractor, BIC-Med, Zernike, VB-RelativeShape}\}$

- Conjunto de Funções de Distância disponíveis para esse contexto:

$M = \{L_1, L_2, L_{inf}\}$

Assim, utilizando-se a metodologia proposta, pode-se estabelecer parâmetros de percepção para cada aspecto visual/semântico definido pelos especialistas em cada contexto. São eles:

- $Ac_1 = \{\text{"Textura Geral da Massa"} \rightarrow \{\text{Haralick, } L_2\}\};$
- $Ac_2 = \{\text{"Proporção de Ar"} \rightarrow \{\text{BulkExtractor, } L_2\},$
 $\text{"Escurecimento de Estruturas"} \rightarrow \{\text{Histograma, } L_1\},$
 $\text{"Espessamento"} \rightarrow \{\text{BulkExtractor, } L_2\}\};$
- $Ac_3 = \{\text{"Proporção de Ar"} \rightarrow \{\text{BulkExtractor, } L_2\},$
 $\text{"Escurecimento de Estruturas"} \rightarrow \{\text{Histograma, } L_1\},$
 $\text{"Espessamento"} \rightarrow \{\text{Histograma, } L_{inf}\}\};$
- $Ac_4 = \{\text{"Distribuição de Cor"} \rightarrow \{\text{Histograma, } L_1\},$
 $\text{"Presença de Fratura Óssea"} \rightarrow \{\text{Histograma, } L_{inf}\}\};$
- $Ac_5 = \{\text{"Deformidade no Corpo Vertebral"} \rightarrow \{\text{VB-RelativeShape, } L_2\},$
 $\text{"Presença de Sinal Vertebral"} \rightarrow \{\text{BIC-Med, } L_1\}\};$
- $Ac_6 = \{\text{"Deformidade no Corpo Vertebral"} \rightarrow \{\text{Zernike, } L_2\},$
 $\text{"Presença de Sinal Vertebral"} \rightarrow \{\text{BIC-Med, } L_1\}\};$

Quando as palavras-chaves que compõem esses parâmetros de percepção são definidos pelos próprios radiologistas, o sistema poderá ser guiado, em cada consulta, para o melhor descritor de cada um desses aspectos visuais da imagem com bastante facilidade, pois o termo utilizado já será de uso habitual do especialista. Com isso, nesse primeiro momento, a eficiência de desempenho também estará relacionada à experiência do especialista em discernir corretamente qual o parâmetro de percepção ele julga ser o melhor para a consulta.

5.3.5 Discussão

Nessa subseção foi apresentada uma proposta de hierarquização e formalização de Critérios de Similaridade e Parâmetros de Percepção para permitir consultas por similaridade em múltiplos contextos pré-definidos. Essas definições permitem uma especificação ainda maior dos possíveis contextos e aspectos visuais de comparação das imagens (o que ajuda a

diminuir a lacuna semântica dos sistemas CBIR) e ao mesmo tempo, ajuda a tornar o Sistema CBIR genérico o suficiente para ser inserido em ambientes onde é preciso uma generalização da aplicação para tratamento das diferentes imagens geradas a todo momento pelos exames radiológicos.

Porém, será que não haveria como automatizar toda essa definição e escolha do contexto e dos parâmetros de percepção? Assim os especialistas poderiam utilizar de sistemas CBIR de forma mais ubíqua, transparente e, caso não queiram ter o trabalho de especificar o contexto ou o aspecto visual desejado, o sistema automaticamente já providenciaria a melhor configuração para uma dada consulta.

5.4 Identificação Automática de Critérios de Similaridade

Em um ambiente hospitalar, a cada nova imagem/exame gerada na radiologia, há a necessidade da mesma ser laudada (classificada). Caso o radiologista deseje consultar um sistema CBIR, as características deverão ser extraídas na hora da consulta? O estudo da literatura da área responde que sim. Mas, e caso ele deseje realizar consultas em diferentes contextos possíveis para aquele tipo de imagem. Teria ele que aguardar cada uma das extrações para depois então visualizar a resposta do sistema? É importante ressaltar que por mais rápida que seja uma aplicação CBIR, há algoritmos de extração de características robustos, porém de alta complexidade, consumindo um tempo considerável, da ordem de muitos minutos, para extração de características.

Para análise de imagens em ambiente real não é viável deixar para extrair características no momento da consulta. Por esse motivo, nessa seção será apresentada uma proposta de identificação automática de critérios de similaridade (ou seja, contextos de análise e parâmetros de percepção), que podem ser aplicados no processo de aquisição e armazenagem das imagens no PACS, ou no registro eletrônico do paciente.

5.4.1 Definição automática de Contextos de Análise

Assim que uma imagem é gerada, uma cópia dessa imagem poderá ser submetida a um processo automático de “análise de requisitos” e “tomada de decisão”. Esse processo pode analisar cada contexto disponível no sistema CBIR, levantar os requisitos necessários

para cada contexto e por fim verificar quais os conjuntos de requisitos são cumpridos pela imagem. Ao verificar em quais contextos uma imagem se encaixa, fica fácil definir a quais métodos de comparação essa imagem se qualifica para ser submetida.

O processo de definição automática de contexto aqui proposto é descrito com o seguinte Algoritmo 2.

Algoritmo 2 Define, com base em Contextos bem definidos pelo usuário da aplicação, quais são os contextos de análise de similaridade que determinada imagem poderá ser submetida. Assim, o algoritmo já inclui automaticamente a imagem em seus contextos específicos.

Entrada: Imagem DICOM gerada por qualquer exame radiológico *Img*, Descrição do Pedido de Exame *Descr*.

```
01: obterTipoExameDoDicom(in: Img, out: tipoExame)
02: obterProtocoloExameDoDicom(in: Img, out: protocoloExame)
03: obterHipoteseDoPedido(in: Descr, out: hipóteseDiagnóstica)
04: obterListaDeContextosPossiveis(in: tipoExame, in: protocoloExame, in: hipóteseDiagnóstica, out: listaDeContextosDeAnálise)
05: para listaDeContextosDeAnálise faça
06: | obterRequisitoDoContexto(in: contextoi, out: requisitoDoContexto)
07: | se requisitoDoContexto então
08: | | executarRequisito(in: requisitoDoContexto, in: Img, out: ImgPréProcessada)
09: | | inserirImagemNoContexto(in: ImgPréProcessada);
10: | senão
11: | | inserirImagemNoContexto(in: Img);
12: | fim se
13: fim para
```

A função “obterListaDeContextosPossiveis” nada mais é que uma verificação na base de contextos pré-definidos pelos especialistas (conforme Seção 5.3) e a validação dos dados da imagem (tipoExame, protocolo e Hipótese Diagnóstica) encontrados no cabeçalho DICOM. Para cada contexto possível encontrado para a imagem, haverá zero, um ou mais requisitos de cada contexto a ser cumprido (como por exemplo uma segmentação automática, ou um janelamento da imagem) para então se chamar a função “inserirImagemNoContexto”. Essa função é responsável por encaminhar a imagem para a extração de características e incluir o vetor de características no(s) índices corretos. A Figura 18 ilustra o modelo de dados necessário para suportar o algoritmo proposto. Além disso, cada campo “descrição” contido nas tabelas do modelo (seja na tabela “contexto”, “descriptor” ou “parâmetro de percepção”) é composto por um arquivo XML com *tags* bem definidas que especificam quais os pré-requisitos que cada imagem deve possuir/passar para se encaixar naquele contexto/descriptor/parâmetroDePercepção, como exemplo na Figura 19.

Figura 18: Modelo de dados para suportar Definição automática de Critérios de Similaridade

A etapa de definição automática de contexto é essencial para se garantir uma alimentação constante do sistema com os novos casos surgidos no hospital. Além disso, essa etapa permite ao CBIR ser utilizado em domínios menos específicos (como realmente é o ambiente real de análise) e ao mesmo tempo, manter a especificidade necessária para aumentar a eficiência e diminuir a lacuna semântica existente no processo de recuperação de imagens por conteúdo.

```

<dataset>
  <name>ROIS_MamaChicago</name>
  <path>F:\BasesOficiais\Mama</path>
  <description>
    <about>The dataset consists of regions of interest (ROIs) obtained from mammography exams extracted from
    DDSM (http://marathon.csee.usf.edu/Mammography/Database.html)</about>
  </description>
  <typeofimage>grayscale</typeofimage>
  <extension>.jpg</extension>
  <numimages>2892</numimages>
  <imageSpecifications>
    <imageClassification>
      <name>Lesao</name>
      <about>As ROIS foram recortadas por médicos da área que focaram em regiões que deixassem no centro
      da roi dois tipos de lesões. São elas: Massa ou Calcificação</about>
      <classes>
        <classValue> Massa </classValue>
        <classValue> Calcificacao </classValue>
      </classes>
    </imageClassification>
    <imageClassification>
      <name>Tipo Da Lesao</name>
      <about>Cada tecido submetido à mamografia foi acompanhado de exame de biópsia para certificação de
      malignidade da lesão.</about>
      <classes>
        <classValue> Benigna </classValue>
        <classValue> Maligna </classValue>
      </classes>
    </imageClassification>
    <imageClassification>
      <name>BIRADS</name>
      <about>Os médicos responsáveis pela ROIS laudaram cada imagem (antes do exame de biópsia) de acordo
      com o padrão BI-RADS. </about>
      <classes>
        <classValue> 1 </classValue>
        <classValue> 2 </classValue>
        <classValue> 3 </classValue>
        <classValue> 4 </classValue>
        <classValue> 5 </classValue>
      </classes>
    </imageClassification>
  </imageSpecifications>
</dataset>

```

Figura 19: Exemplo de arquivo XML para especificação de requisitos de Contexto/Descritores/ParâmetrosDePercepção

5.4.2 Identificação automática de Parâmetros de Percepção

Após a etapa de definição automática de contextos, cada imagem submetida ao processo terá suas características extraídas de acordo com os contextos em que se encaixa. Para cada contexto, haverá um ou vários descritores pelos quais a imagem terá características extraídas (de acordo com o número de Parâmetros de Percepção que cada contexto apresentar). Assim, no momento da consulta, mesmo tendo um contexto bem definido para aquele tipo de imagem, como estabelecer qual parâmetro de percepção melhor representará aquela imagem (em uma primeira consulta onde o usuário não deseja indicar o parâmetro de percepção) e, conseqüentemente qual descritor deve ser utilizado nessa situação?

O Algoritmo 3 estabelece um meio para definição automática de qual parâmetro de percepção será utilizado na consulta inicial, quando o médico opta por não definir o parâmetro de percepção a ser utilizado na consulta. Essa definição automática é realizada por um classificador k-NN, onde, dadas as imagens mais similares para cada parâmetro de percepção disponível, o resultado da consulta vai guiando, de acordo com a classificação de maior grau de Confiança (ou seja, classe majoritária) qual parâmetro conseguiu retornar a

classe majoritária com o maior grau de confiança. Todas essas informações também são armazenadas no sistema, conforme modelo apresentado.

Algoritmo 3 Define, com base em uma Classificação k-NN, qual parâmetro de percepção melhor se adéqua a uma dada imagem.

Entrada: Identificador da imagem de consulta *idImagem*.

01: obterListaDeContextos(in: *idImagem*, out: *listaDeContextosDeAnálise*)

02: **para** *listaDeContextosDeAnálise* **faça**

03: | obterParâmetrosDePercepção (in: *contexto_i*, out: *listaParametrosPercepção*)

04: | **para** *listaParametrosPercepção* **faça**

05: | | consultaKNN(in: *idImagem*, in: *parâmetro_j*, k, out: *listaSimilares*);

06: | | obterClasseMajoritaria(in: *listaSimilares*, out: *classe*, out: *grauConfiança*);

07: | | **se** *aux* < *grauConfianca* **então**

08: | | | *auxClasse* = *classe*;

09: | | | *aux* = *grauConfiança*;

10: | | **fim se**

11: | **fim para**

12: | obterParametroPercepcao (in: *auxClasse*, out: *auxParametro*);

13: | inserirParametroInicialDaImagemContexto(in: *contexto*, in: *idImagem*, in: *auxParametro*);

14: | **fim se**

15: **fim para**

16: obterParametroPercepcao (in: *auxClasse*, out: *auxParametro*);

17: inserirParametroInicialDaImagemGeral(in: *idImagem*, in: *auxParametro*);

Esse algoritmo de definição automática de parâmetro de percepção com base em classificação k-NN também pode ser utilizado como base para sugestão diagnóstica ao médico. Apesar dessa funcionalidade não ter sido avaliada em ambiente real, ela foi incluída na aplicação. A decisão do sistema sobre qual parâmetro de percepção deve ser utilizado é tomada com base na classificação k-NN (tomando a classe majoritária dentre as imagens retornadas como similares como sendo a classe da imagem de consulta). Essa classificação automática é apresentada ao radiologista que pode considerá-la como uma segunda opinião diagnóstica. Um exemplo dessa aplicação pode ser visto na Figura 20, onde no canto esquerdo, logo abaixo da imagem de consulta, o sistema apresenta um sugestão diagnóstica para a imagem. No caso foi “Calcificação”, pois 73.33% das imagens retornadas como sendo similares também eram dessa classe.

5.5 Experimentos em Ambiente Real

O Sistema Higiiia, desenvolvido pelo aluno e descrito na Seção 3.4 possibilitou a realização dos experimentos práticos em Ambiente Real no HC-FMRP para avaliar a sistematização

proposta neste capítulo.

5.5.1 Materiais e Métodos

O experimento contou com a colaboração de 04 especialistas do HC-FMRP e envolveu os seguintes contextos de análise:

- $c_1 = \{ \text{“mamografia”, “ROI”} \}$
- $c_2 = \{ \text{“RM da Coluna Vertebral”, “Vértebras da Coluna Lombar”} \}$

Os parâmetros de percepção utilizados nesses experimentos foram:

- $Ac_1 = \{ \text{“Textura Geral da Massa”, “Variação de Cor”} \}$
- $Ac_2 = \{ \text{“Deformidade no Corpo Vertebral”, “Presença de Sinal Vertebral”} \}$

O primeiro contexto utilizou um conjunto de 2892 imagens de regiões de interesse (ROIS) de exames de mamografia classificadas com massa ou calcificação. O segundo contexto utilizou um conjunto de 171 imagens de coluna vertebral, também selecionadas por especialistas da área e separadas em duas classes distintas (normais e com lesão).

Nesse experimento foi apresentado ao especialista uma imagem e, logo em seguida, os resultados de duas consultas por similaridade utilizando aquela imagem como centro de consulta. Foi utilizado um $k = 15$, para o número de imagens mais semelhantes a serem retornadas. A diferença nas consultas estava na escolha automática do descritor. O resultado da primeira consulta foi obtido utilizando o conceito de “Parâmetro de Percepção” e os algoritmos de definições automáticas propostos na tese, já a segunda consulta apresentada foi realizada sem a utilização do conceito de “Parâmetro de Percepção”, nesse caso, a metodologia tradicional, utilizando o melhor descritor médio para a base toda. As duas respostas foram apresentadas ao especialista que, após análise, escolhia a que melhor se encaixava com sua própria percepção, ou seja, qual das respostas estava mais adequada à situação diagnóstica colocada.

Figura 20: Exemplo de tela do Sistema Higiia

A Figura 20 mostra um exemplo da interface do sistema Higiia utilizado pelos experimentos. Nela a imagem de consulta é apresentada no canto superior esquerdo, as imagens respostas, com a possibilidade de visão dos laudos (diagnósticos) das imagens retornadas e a sugestão diagnóstica baseada em classificação IBL/k-NN utilizada para definição automática de parâmetros de percepção, no quadro à direita. A imagem maior, na parte central, pode ser qualquer imagem clicada pelo médico, com o objetivo de disponibilizar uma visão maior e mais detalhada, com possibilidade de zoom e janelamento da imagem escolhida para análise.

5.5.2 Resultados

Para as imagens de mama foram realizadas um total de 24 consultas, utilizando em 12 delas o conceito de “Parâmetro de Percepção” e em 12 o modo tradicional de consultas CBIR da literatura. Foram realizadas também 52 consultas utilizando imagens de Coluna como referência (26 delas com o conceito de “Parâmetro de Percepção” e 26 de modo tradicional CBIR da literatura). A Figura 21 ilustra os resultados obtidos a partir da escolha dos especialistas.

Quando analisamos o desempenho do sistema separado por classe, percebemos algo muito interessante. Para imagens de coluna classificadas como “Normal” (ou seja, não contendo aspectos visuais que caracterizam lesão), 93% dos especialistas escolheram a

resposta “Sem o Parâmetro de Percepção”. Já para as imagens contendo algum tipo de fratura, 73% escolheram a resposta “Com o parâmetro de percepção”. Resultado semelhante foi constatado com as imagens de Mama. Nessas, 66% e 100% dos especialistas escolheram a resposta dada “com o Parâmetro de Percepção” para imagens contendo massa e calcificação respectivamente.

Figura 21: Resultado da escolha dos especialistas para consultas com e sem o Parâmetro de Percepção

5.6 Considerações Finais

Neste capítulo a visão de critérios de similaridade foi decomposta, descrita e sistematizada de maneira a permitir o suporte à busca por conteúdo em diferentes níveis de especificidade. O capítulo apresentou um arcabouço teórico que padroniza diferentes níveis de especificidade para definição e identificação de Critérios de Similaridade e a inclusão de Parâmetros de Percepção durante a comparação de imagens médicas em sistemas CBIR. Toda essa contribuição teórica proposta na tese ajudou na construção de métodos que colaboram com a solução do paradoxo apresentado na introdução deste capítulo. Apesar do grande estudo bibliográfico realizado nesta tese, com ele não foi possível encontrar algum trabalho que faça uma contribuição nesse nível. Ou seja, de possibilitar a um Sistema CBIR ser específico a

diversos contextos médicos e, ao mesmo tempo, incorporar métodos que o tornam genérico a ponto de se tornarem viáveis de serem aplicados em um ambiente real.

O primeiro método proposto após a formalização do arcabouço teórico foi a Definição Automática de Contexto. Com ele, foi possível trabalhar, ao mesmo tempo, com três contextos bem distintos e específicos (RX de mama, CT de Pulmão e RM de Coluna Vertebral), além do que, a definição apresentada permite inclusão de outros contextos de análise conforme foi mostrado pelo Estudo de Caso Teórico. O segundo método proposto, a Definição Automática de Parâmetros de Percepção, veio como avanço do sistema para uma escolha automática da melhor configuração de análise baseada nos diagnósticos das imagens similares. Assim o especialista não fica obrigado a escolher o parâmetro de percepção se quiser melhorar o desempenho da primeira consulta. Os experimentos mostraram que a influência do uso de parâmetros de percepção é bastante considerável, sendo que, no caso das imagens de mama, conseguiu-se uma melhora de 12,5% na precisão média do sistema, além de poder mostrar a classificação baseada nos diagnósticos das imagens similares como sugestão diagnóstica ao médico (segunda opinião) na ocasião da confecção do laudo.

Por fim, o experimento prático, realizado em ambiente real com imagens de RX de mama e RM de Coluna Vertebral, mostrou a aprovação do método pelos radiologistas nos casos onde há achados/doenças nas imagens a serem diagnosticadas. Assim, a exploração desse tipo de sistema CBIR como potencial sistema CAD poderá trazer grandes benefícios à atuação dos especialistas no ambiente real.

Capítulo 6 – Representação de Imagens de Coluna Vertebral para CBIR Perceptual

6.1 Considerações Iniciais

Diferentes sistemas, com diversas técnicas e algoritmos para CBIR em imagens de coluna vertebral estão disponíveis na literatura (ver Seção 3.4), porém, a maioria dos trabalhos estudados utilizam dois tipos de abordagens para extração de características. Uma abordagem considerando características “globais” e outra considerando características “locais”. A abordagem global extrai características considerando uma análise da imagem completa, sem qualquer tipo de segmentação ou especificação de contexto além do tipo do exame. Já a abordagem local utiliza algoritmos de segmentação de imagens para analisar apenas uma ROI (no caso, cada corpo vertebral), extraindo características de cada vértebra da coluna presente na imagem, considerando cada vértebra separadamente. No entanto, durante estágio em ambiente hospitalar realizado durante esta pesquisa, foi verificado que nenhuma dessas duas abordagens se assemelham com o processo de análise do especialista no momento de comparação entre casos similares. Assim, neste capítulo, é proposto um método de comparação entre imagens de coluna, bem como duas adaptações de algoritmos tradicionais de extração de características, que busca aproximar-se da percepção do especialista durante análise de lesões na região lombar da coluna vertebral em imagens de Ressonância Magnética.

Além dos trabalhos específicos para coluna, há também os CBIRs ditos genéricos, como descritos na Seção 3.4, que podem incorporar técnicas específicas ao tipo de imagem discutido neste capítulo. No entanto, mesmo com tanta pesquisa, existem desafios específicos a serem superados, e um deles é a aproximação do padrão de semelhança expresso por algoritmos CBIR daquele esperado pelo especialista. No entanto, para atingir este nível há a necessidade de se estabelecer métodos de comparação compatíveis com os métodos utilizados pelos próprios radiologistas, na prática clínica, conforme proposto neste capítulo.

6.2 Metodologia Proposta

Para este trabalho, foi considerado que mecanismos de busca por similaridade

construídos/implementados com base em conhecimento extraído da análise realizada pelos próprios radiologistas são chamados de *Perceptual-Based*. Com algumas exceções, os métodos humanos utilizados pelos especialistas do domínio, quando estão comparando duas imagens em ambiente real, não são usualmente considerados e nem mesmo explorados durante construção de sistemas CBIR tradicionais. Visando criar um mecanismo de comparação próximo ao utilizado pelos radiologistas, vários questionamentos e observações foram realizados junto aos médicos, residentes e radiologistas, do Centro de Ciências das Imagens e Física Médica (CCIFM) do Hospital das Clínicas de Ribeirão Preto (HC-FMRP). O objetivo foi extrair informações de como os especialistas do domínio comparam imagens contendo os achados descritos na Seção 4.4.3 desta tese. Com as informações coletadas o seguinte método foi proposto.

6.2.1 Representação das Imagens de Coluna para CBIR Perceptual

Analizando a Figura 22, percebe-se que as imagens A_1 , A_2 e A_3 são relativamente similares entre si. Porém, uma análise detalhada das imagens leva o observador às seguintes conclusões:

- Uma análise global, considerando a imagem como um todo. Nesse caso, provavelmente o observador julgará as imagens A_2 e A_3 mais similares entre si.
- No entanto, em uma análise focada em um domínio mais específico, por exemplo analisando apenas a coluna lombar, tal como as imagens A'_1 , A'_2 e A'_3 , provavelmente o observador concluirá que são as imagens A_1 e A_2 as mais similares entre si (e não as ditas na primeira observação).
- Extrapolando para um contexto mais local, focado apenas nas ROIs ($B_{1,1}$, $B_{1,2}$ e $B_{1,3}$), o observador pode ainda chegar a uma terceira conclusão, diferente das duas primeiras.

O exemplo citado acima caracteriza bem a diferença entre o que o especialista pode acreditar como sendo similar e aquilo que o sistema pode julgar como sendo similar (i.e., *gap* semântico). Provavelmente um descritor de cor ou textura, aplicado à imagem inteira (*Global-Based*) retornaria erroneamente as imagens A_2 e A_3 como sendo as mais similares entre si. Percebendo isso, na tentativa de reduzir o *gap* semântico, muitos trabalhos buscam especificar ainda mais o contexto, abordando somente consultas considerando regiões locais bem específicas (*ROIs-Based*), conforme Seção 3.4. Porém, mesmo esses métodos locais trazendo melhores resultados, novas disparidades semânticas poderiam estar sendo criadas.

Exatamente como mostrado no exemplo acima, onde uma consulta local provavelmente traria as imagens A_1 e A_3 como mais similares. Sem falar que, ao comparar duas imagens: 1) Exigir marcação de ROIs no momento da análise acaba sendo um trabalho extra a ser realizado pelo radiologista e, 2) Quando se considera apenas ROIs semelhantes, o médico pode se deparar com imagens que têm diferentes regiões representativas (como é o caso dos corpos vertebrais), onde poderá haver regiões normais e não normais na mesma imagem. Esse fato geraria grande confusão ao se comparar casos inteiros.

Além do exposto acima, no contexto específico tratado neste capítulo, consultas puramente locais ou puramente globais ainda são distantes daquilo que a análise do especialista naturalmente considera para cálculo de similaridade. Nesse contexto o radiologista considera variações entre regiões vizinhas e não apenas uma única região. Por isso, a seguinte metodologia de representação foi proposta e explorada neste capítulo.

Figura 22: Diferentes métodos para se comparar imagens médicas.

A fim de se adaptar a extração de características para algo próximo ao conceito de similaridade percebida por radiologistas, foi proposto um método que extrai as características locais (baseada em ROIs), compondo em um único vetor, as características de cada vértebra de forma ordenada e reconhecida em um único vetor de características. Essa metodologia

permite que cada vértebra pertencente à imagem analisada seja comparada unicamente com a vértebra equivalente em outra imagem. Assim, a semelhança entre duas imagens não é calculada considerando uma única região, mas considerando-se a variação existente entre todas as regiões de uma dada vizinhança.

6.2.2 Extração de Características Baseada em Análise da Coluna

Para modelar as características visuais descritas na Subseção 4.4.3, os seguintes descritores de cor e forma foram desenvolvidos:

Extrator de Cor do Corpo Vertebral (BIC-Med) O algoritmo BIC (*Border Interior Classification*), apresentado na subseção 2.2.2, foi originalmente desenvolvido (Stehling et al. 2002) para extração de características em imagens tradicionais RGB. Já as imagens médicas são usualmente expressas em níveis de cinza, com 16 bits por pixel. Esse formato possibilita imagens com até 4096 níveis de cinza. Consequentemente, devido a pequenas alterações e/ou ruídos durante a captação do sinal, o interior dos objetos encontrados nessas imagens médicas não apresentam sempre a mesma intensidade (mesmo valor) de pixel. Pequenas variações nesses níveis de cinza contidos em um mesmo objeto podem ser consideradas normais nesse contexto. Dessa forma, o uso do algoritmo BIC pode trazer grande confusão na classificação dos pixels e contagem dos níveis de pixel de uma imagem, principalmente devido a possibilidade de erro na classificação entre o que é borda e o que é interior dentro de cada imagem.

Figura 23: Classificação dos pixels entre Borda (pixel cinza) e Interior (pixel Branco) utilizando o algoritmo a) BIC Tradicional e o b) BIC-Med.

Para solucionar esse problema, este trabalho propõe uma modificação na maneira como os pixels são classificados entre borda/interior, propondo o BIC-Med. Com esse novo mecanismo o pixel da imagem é classificado como “borda” SE pelo menos um de seus 04 vizinhos conectados apresentam uma variação de quantização de nível de cinza MAIOR que um dado *threshold*. Além disso, SE todos os seus 04 vizinhos conectados apresentarem uma variação MENOR que (ou igual) a um dado *threshold*, esse pixel é classificado como “interior”. A parte final do algoritmo é responsável por concatenar os dois histogramas, gerando um vetor de características da imagem com 16 posições, onde nas primeiras 08 posições haverá um histograma dos pixels classificados como “borda” e nas 08 últimas posições um histograma dos pixels classificados como “interior”. O *threshold* considerado para os experimentos deste trabalho foi de uma variação relativa de 20% do valor do nível de cinza de cada pixel. Esse valor de variação de intensidades foi escolhido empiricamente, com base em uma série de experimentos.. A Figura 23 apresenta uma ilustração da aplicação dos dois métodos de classificação (o BIC tradicional e o BIC-Med) para uma imagem da coluna vertebral.

Extrator de Forma do Corpo Vertebral (VB-RelativeShape) O extrator de forma proposto neste trabalho foi também criado com base na percepção médica de análise de fraturas do corpo vertebral proposto por Genant (Genant et al. 1993)(Ribeiro et al. 2011). Essa metodologia de percepção de análise citada prevê uma escala de zero a três, considerando a diferença entre os valores máximo e mínimo da altura do corpo vertebral medidas em três regiões da vértebra: a anterior (AH), a central (CH) e a posterior (PH). Na escala citada são estabelecidos os valores de *score* entre 0 (normal) para uma diferença percentual menor que 20%, até um *score* 3 (fratura severa), onde essa diferença percentual entre as alturas chegue a um valor maior que 40%. Com o conhecimento exposto acima, o extrator de característica proposto neste trabalho, chamado de *VertebralBody-RelativeShape* (VB-RelativeShape), extrai três valores representativos de cada corpo vertebral. Esses valores referem-se à proporção relativa entre as alturas anterior, central e posterior da vértebra. Ou seja, cada corpo vertebral é representado pela proporção de três medidas principais. São elas:

$$v_{i,j} = [AH/CH, AH/PH, CH/PH]$$

onde v é o vetor de características e as medidas AH, CH e PH são as alturas anterior, central e posterior correspondentes à vértebra j da imagem i . A Figura 24 ilustra as medidas propostas

acima para a composição do vetor representativo a cada corpo vertebral. Uma grande vantagem dessa representação é que como o extrator é composto pela proporção entre as alturas da vértebra (percentual de uma altura com relação a outra), o extrator passa a ser invariante à alteração de tamanho do corpo vertebral. Isso é importante pois é natural que uma vértebra de criança seja menor que uma de adulto, porém, quando apresentarem uma mesma lesão, o seu tamanho real não impedirá de ambas serem recuperadas como semelhante.

Assim, o vetor de características representativo da imagem, visando comparação da coluna lombar, seria formado pela concatenação dos vetores de cada um dos 05 corpos vertebrais correspondentes à coluna lombar:

$$V_i = [V_{i,1}, V_{i,2}, V_{i,3}, V_{i,4}, V_{i,5}]$$

Figura 24: Representação da Forma do Corpo Vertebral

6.3 Experimentos

Para avaliar a metodologia proposta neste capítulo, foram gerados gráficos de Precisão vs. Revocação para comparação de acurácia na recuperação de imagens de mesma classe (tidas como similares). A precisão dos extratores específicos do contexto foi analisada nas três metodologias apresentadas (Global, Perceptual e Local) para viabilizar uma análise do comportamento de cada extrator mediante a metodologia de comparação submetida. A metodologia proposta foi comparada com as metodologias tradicionais (Global e Local, apresentadas na Seção 3.2) encontradas na literatura.

6.3.1 Materiais e Métodos

A realização dos experimentos utilizou uma base de imagens médicas selecionada entre exames de RM realizados no Hospital das Clínicas de Ribeirão Preto (HC-FMRP). O

conjunto de imagens contém 171 imagens, selecionadas por especialistas da área e separadas em duas classes distintas (83 imagens normais e 88 imagens contendo Fraturas por Compressão Vertebral). Para viabilizar os experimentos focando na coluna vertebral, especialistas do HC-FMRP realizaram uma segmentação manual da coluna lombar, segmentando os corpos vertebrais contidos nas imagens. Com essa segmentação manual foi possível também criar uma outra base de testes, específica de ROIs, contendo 855 imagens de corpos vertebrais da coluna lombar.

Para a representação das características visuais desse contexto, foram extraídos das imagens vetores de características relativos à cor e forma dos corpos vertebrais. Foram utilizados alguns extratores tradicionais, descritos na Seção 2.2.2, bem como os extratores propostos neste capítulo. Os **extratores de cor** são o BIC tradicional e sua extensão, proposta nesta tese e chamada de BIC-Med. Os **extratores de forma** são o extrator proposto, chamado de VB-RelativeShape e o extrator tradicional de forma conhecido como Momentos de Zernike (Seção 2.2.2).

6.3.2 Resultados

Analisando os extratores de características propostos neste capítulo, ambos apresentaram melhor desempenho quando comparados aos algoritmos tradicionais. Essa superação ocorreu tanto na metodologia de comparação local (baseada em ROIs) quanto na metodologia proposta, baseada no modo de percepção e comparação dos radiologistas (*Perceptual-Based*).

Figura 25: Desempenho de diferentes métodos para se comparar imagens de coluna.

Os gráficos da Figura 25 ilustram o desempenho dos extratores em cada metodologia. Ao se comparar as curvas, percebe-se que a precisão média do BIC-Med nos primeiros 20% de recall foi superior a 80% de precisão, enquanto o BIC tradicional não chegou a este nível. Esse comportamento pode ser visto tanto na abordagem local quanto na abordagem perceptual. Durante análise da abordagem local (ROIs), observando o comportamento dos extratores de forma, tanto o *VB-RelativeShape* quanto o *Zernike* apresentaram um desempenho muito similar. No entanto, ao se analisar o desempenho desses extratores na abordagem perceptual de comparação de imagens, a precisão dos dois extratores melhorou bastante e, nesse caso, o *VB-RelativeShape* apresentou um ganho significativo em comparação com o *Zernike* (cerca de 10% melhor nos primeiros 20% de *recall*).

Figura 26: Diferentes métodos para se comparar imagens médicas.

Outro resultado interessante a ser analisado é o comportamento dos diferentes extratores nas diferentes metodologias de comparação de imagens (*Global-Based*, *Perceptual-Based* ou *RoIs-Based*). A Figura 26 ilustra o desempenho de cada extrator nessas diferentes abordagens. O BIC e Zernike, que originalmente são extratores genéricos (não específicos) e originalmente implementados para análise global da imagem, realmente mostraram melhor desempenho na abordagem global. Ambos perderam desempenho quando utilizados nas abordagens perceptual e baseada em ROIs. Já o extrator BIC-Med, foi o que apresentou melhor desempenho em quase todos os cenários, principalmente quando analisado nas abordagens perceptual e baseada em ROIs. Em se tratando da análise de forma, o VB-RelativeShape apresentou um alto ganho na precisão quando utilizado na abordagem perceptual (*Perceptual-Based*). Esse resultado confirma a afirmação dos especialistas quando dizem que, no caso da forma, e de certa forma também no caso de extratores de cor, a descrição considerando toda a vizinhança apresenta uma aproximação maior com a realidade do que se considerar apenas uma única região de interesse.

6.4 Considerações Finais

Neste capítulo foi apresentada uma nova metodologia de representação de imagens de coluna que visa diminuir o *gap* semântico existente entre a análise humana e a modelagem computacional tradicional existente na literatura para esse tipo de imagem. Foi proposto um

método de comparação que busca imitar a lógica de percepção do especialista durante a análise de lesões em imagens de Ressonância Magnética de coluna. Foram propostos também dois tipos de representação de características visuais das imagens, um para características de cor e outra para representação de forma do corpo vertebral. O primeiro com base na adaptação de um extrator de cor tradicional (o BIC) e o segundo com base na própria descrição de análise dos especialistas. A metodologia proposta (Perceptual-Based) alcançou melhores resultados nos experimentos realizados, mostrando que não apenas a extração de características, mas também a maneira de comparação automática de imagens deve considerar os aspectos visuais relevantes definidos pelos especialistas dentro de um contexto específico.

Capítulo 7 – Avaliação da Viabilidade Clínica de um CBIR em Ambiente Real

7.1 Considerações Iniciais

Há na literatura diversas propostas de sistemas CBIR para imagens médicas (Akgül et al. 2011)(Deserno et al. 2011). Uma aplicação clara desses sistemas consiste na disponibilização de imagens armazenadas que são visualmente similares a uma nova (e não diagnosticada) imagem. Essa abordagem permite que os radiologistas analisem diagnósticos e tratamentos realizados em exames passados (casos similares), informações que podem auxiliar na tomada de decisão. No entanto, a grande maioria dos trabalhos relatados em CBIR não verificam como os especialistas se comportam na presença desses sistemas durante suas atividades de rotina diagnóstica. Na Seção 3.4 são apresentados trabalhos da área cuja avaliação apresentada não modela com precisão o processo de diagnóstico convencional realizado pelos radiologistas, além de não apresentar interatividade para realimentação por relevância. Essa falta de estudo prático adequado, abordando o impacto do CBIR no ambiente médico, pode aumentar a desconfiança dos especialistas nesse tipo de sistema e ainda desacelerar o avanço dessas ferramentas como meio de auxílio ao diagnóstico.

Além do exposto acima, não foram encontrados na literatura estudada trabalhos que apresentem uma proposta de análise voltada para o comportamento dos usuários durante processo de classificação de imagens atrelado à mudança do grau de certeza do especialista na classificação realizada, como proposto nesta tese. Essa expressão do grau de certeza foi avaliada como positiva, pois capta um sentimento complexo envolvido na classificação das imagens. Outra exigência dos especialistas, desenvolvida neste trabalho, que não é encontrada nos demais sistemas ou avaliações estudadas, foi a possibilidade de exclusão de imagens irrelevantes para redução de ruído visual causado por elas durante análise das imagens similares.

Neste capítulo é apresentada a análise de um sistema CBIR Médico, centrada no usuário, em termos de auxílio no processo de diagnóstico e classificação de imagens. Foi acompanhado também o grau de confiança do usuário nesse tipo de tarefa, tendo o sistema como apoio. Para a realização dos testes, foi desenvolvido um sistema CBIR que possibilita a inclusão de laudo (classificação) de uma dada imagem. Para evitar ambiguidades, os campos de classificação foram implementados em múltipla escolha, com diagnósticos pré-definidos.

O sistema também questiona os usuários sobre a sua confiança no diagnóstico em cada ciclo de interação, permitindo a captura de possíveis mudanças no grau de certeza do radiologista após contato com imagens (casos) similares.

7.2 Metodologia Proposta

A Figura 27 ilustra a abordagem proposta para avaliação da viabilidade clínica de sistemas CBIR na área médica. Na etapa 1 o sistema apresenta uma imagem não diagnosticada ao médico, que a visualiza e realiza uma primeira classificação (laudo). Na etapa 2, o especialista atribui um determinado grau de certeza sobre sua própria classificação, e, logo em seguida, no passo 3, decide se irá realizar ou não uma consulta por similaridade para apoiar seu diagnóstico e/ou melhorar o nível de certeza no diagnóstico atribuído. No passo 4 o sistema executa uma consulta por similaridade, utilizando a imagem não diagnosticada como o centro de consulta, e exibe as imagens recuperadas consideradas pelo sistema como sendo semelhantes. Nas etapas 5 e 6, o especialista é incentivado a indicar, dentre as imagens retornadas, quais são as imagens irrelevantes, aquelas que nada tem a ver com a imagem de consulta e, por isso, são imediatamente eliminadas da interface, e quais são as imagens relevantes. Finalmente, no passo 7, o radiologista vê o laudo/classificação das imagens relevantes recuperadas. O sistema permite que o especialista visualize os laudos (classificações) das imagens retornadas. Esse processo de análise pode ou não ajudar na tomada de decisão (e é justamente o objeto de estudo nesse caso). Após estas etapas é solicitado ao especialista uma reclassificação da imagem não diagnosticada, bem como o fornecimento do atual grau de certeza sobre a classificação realizada. Assim, fecha-se um ciclo e o *pipeline* retorna aos passos 1 e 2. É importante observar que, nesse ponto, o especialista pode manter a classificação e/ou o grau de certeza fornecidos inicialmente. Por fim, se o especialista ainda não está satisfeito com os resultados (ou seja, ainda não tem uma certeza suficiente para finalizar a interação com o sistema) e quer refinar a pesquisa, isso pode ser realizado através de realimentação por relevância, que é introduzido no processamento da consulta. Para esse experimento, os usuários foram estimulados a experimentar pelo menos uma iteração para realizar realimentação por relevância (utilizando o algoritmo de Rocchio(J J Rocchio 1971)). Assim, todos poderiam refinar a consulta com base em seu próprio conceito de similaridade e analisar novamente os resultados de similaridade retornado pelo sistema. A partir daí os usuários poderiam utilizar quantos ciclos de realimentação quisessem, conforme julgassem necessário para melhorar a precisão e a

certeza de seu próprio diagnóstico.

Figura 27: Metodologia proposta para avaliação de viabilidade clínica em Sistemas CBIR

Todas as interações do usuário com o sistema foram monitoradas e armazenadas em uma base de dados para posterior análise dos resultados. Foram armazenadas quais imagens foram marcadas como relevantes ou irrelevantes, quais classificações foram realizadas em cada um dos ciclos, bem como as sucessivas mudanças na classificação e, principalmente, no grau de certeza de cada usuário do sistema.

7.3 Experimentos

Com o apoio de 10 diferentes radiologistas foi realizado um experimento prático no Hospital das Clínicas de Ribeirão Preto (HC-FMRP) para avaliação da viabilidade clínica de um CBIR. Os resultados relatados nessa seção foram obtidos utilizando-se imagens de mamografias digitalizadas. Esse domínio específico foi escolhido porque o diagnóstico do câncer de mama ainda é um grande desafio a ser explorado e a mamografia é atualmente a forma mais eficaz de se realizar a detecção precoce para possível tratamento dessa doença (Doi 2007). A metodologia utilizada permitiu medir a influência do sistema no diagnóstico realizado pelos especialistas.

7.3.1 Materiais e Métodos

Buscando aplicar a metodologia proposta para análise de influência de um sistema

CBIR em um ambiente real, o pesquisador desenvolveu um Sistema CBIR chamado Higiiia, descrito na subseção 3.4. Essa versão de interface do sistema foi desenvolvida especificamente para captar o comportamento dos especialistas e, conseqüentemente, com os dados coletados, analisar a viabilidade clínica desse tipo de sistema. Toda a interface de classificação foi definida de acordo com os requisitos previstos por especialistas do Centro de Ciências das Imagens e Física Médica (CCIFM) do HC-FMRP.

A base de imagens separada para realização desses experimentos foi disponibilizada pelo HC-FMRP. O conjunto consiste em 2892 imagens de regiões de interesse (ROIS), obtidos a partir de exames de mamografia extraídos de uma base de imagens de domínio público, a DDSM⁵. Essa base divide-se em duas classes: Massa e Calcificação.

Além das imagens, há na base outras informações a respeito dos exames que compõem o conjunto de dados. Nessas informações estão incluídas uma classificação da densidade da mama, uma classificação conforme a sutileza das lesões e o *Breast Imaging Reporting and Data System* (BI-RADS), proposto pelo Colégio Americano de Radiologia (ACR) como um padrão de comparação e classificação de mamografias. A Figura 28 ilustra exemplos das imagens do conjunto de dados utilizado.

Figura 28: Exemplo de imagens da Base de mama

Para a realização das consultas por similaridade, foram extraídas das imagens da base características de cor utilizando um extrator tradicional de histograma de níveis de cinza. A escolha do extrator tomou por base o desempenho contrastante na representação das diferentes lesões encontradas na imagem. Isso permitiu uma análise do comportamento dos especialistas em duas situações contraditórias. O histograma de nível de cinza apresentou uma precisão razoável em relação a uma classe (mais de 60% para a classe “Massa”) e uma precisão muito ruim para a outra (cerca de 40% para a classe calcificação), isso utilizando a

⁵ <http://marathon.csee.usf.edu/Mammography/Database.html>

distância euclidiana (L2) como a função de dissimilaridade. Com essa configuração julgava-se que para as imagens da classe de massa o sistema ajudaria no diagnóstico (e a ideia é saber o quanto ajudaria) e, para as imagens da classe calcificação, seria medido o quanto poderia o sistema confundir ou não o especialista. Essa contradição de resultados foi importante para verificar em quais situações (positivas e/ou negativas) os usuários considerariam a resposta do sistema ou confiariam somente na própria percepção. Assim, com esse objetivo, não foi revelado para os especialistas a diferença de eficácia do extrator nas diferentes situações.

Durante todo o processo do experimento, 10 especialistas participaram do experimento, incluindo radiologistas e médicos residentes do CCIFM e do HC-FMRP. Trinta (30) imagens foram aleatoriamente selecionadas como centros de consulta para a realização do experimento, porém, buscou-se manter a proporcionalidade entre as classes (massa, calcificação e Bi-Rads) apresentadas pela base completa. Cada radiologista analisou uma média de seis imagens e cada imagem foi analisada em média por dois profissionais diferentes. Ao final do experimento foi realizado um total de 65 classificações. Cada consulta k-NN realizada retornava as 15 imagens mais similares à imagem de referência.

7.3.2 Resultados

A metodologia descrita (Seção 5.3) foi aplicada para se obter e analisar os resultados apresentados nesta seção. Para análise dos resultados obtidos pelo sistema foi utilizada a precisão média alcançada pelo sistema através dos resultados das consultas por similaridade. A precisão de cada consulta é computada pela fração dos elementos recuperados que são relevantes (ou seja, de mesma classe da imagem de consulta) obtida pela área abaixo da curva de Precisão e Revocação. A classificação realizada pelos especialistas foi avaliada utilizando a taxa de acerto (acurácia) dos médicos nas classificações realizadas.

Tabela 15: Precisão do médico durante classificação e Precisão do Sistema CBIR (área abaixo da curva de Precisão e Revocação)

Massa			
	1ª Iteração	2ª Iteração	3ª Iteração
Taxa de Acerto do Médico	89%	93%	93%
Precisão do Sistema		61%	62%
Calcificação			
	1ª Iteração	2ª Iteração	3ª Iteração
Taxa de Acerto do Médico	47%	31%	27%
Precisão do Sistema		39%	41%

Na Tabela 15, que apresenta a visão da taxa de acerto do médico e a precisão do sistema, pode-se notar que, utilizando um sistema com valores de precisão em torno de 61% (no caso de imagens contendo Massa), a precisão do especialista aumentou para 93% logo após o primeiro contato com o Sistema. Em contraposição a esse resultado, encontra-se o uso do sistema para imagens contendo Calcificação. Nesse caso, o sistema apresentou uma precisão média entre 39% e 41%, considerando o desempenho na consulta inicial e no primeiro ciclo de realimentação. Esse desempenho mostra que a maioria das imagens retornadas pelo sistema foi da classe oposta à imagem de consulta. Esse comportamento do sistema causou uma confusão na análise do radiologista, diminuindo bastante a taxa de acerto do médico de 47% para 31% e depois 27% após o primeiro e o segundo contato com o sistema respectivamente. Esse mesmo comportamento pode ser observado nos gráficos da Figura 29 (a) e (b). Estes gráficos ilustram a taxa de acerto obtida pelo especialista e a taxa de acerto obtida pelo sistema (no caso, considerando o sistema como um classificador 15-NN).

Figura 29: Comparação entre precisão do Médico e do Sistema em classificar as imagens

Paralelamente à classificação das imagens, os radiologistas também expressaram o grau de confiança (ou grau de certeza) no próprio diagnóstico dado à imagem de consulta. Esse grau de certeza foi discretizado nos valores: 0 (totalmente incerto), 1 (um certo grau de incerteza), 2 (certeza moderada), 3 (algum grau de certeza) e 4 (completamente confiante).

Em uma análise geral, observando os dados referentes a essa expressão de confiança na própria classificação considerando as duas classes de imagens e todas as classificações efetuadas na primeira iteração do processo, 55.38% das imagens foram classificadas com um grau de certeza entre 0 e 2; 32.32% foram avaliados com grau de certeza 3 e 12.30% das classificações foram atribuídas com grau de certeza 4. Das classificações que receberam grau de certeza entre 0 e 2 e das classificações que receberam grau de certeza 3, 25% e 4.76% respectivamente sofreram modificações no valor da certeza após a primeira interação com o sistema. No total, de todas as classificações realizadas na primeira iteração do processo,

15.38% foram reclassificadas ou tiveram o seu grau de certeza modificado. Destes, 60% ocorreram durante a segunda iteração do processo (primeiro contato com as imagens similares) e o restante ocorreu nas iterações seguintes (com a utilização de realimentação de relevância). Para uma melhor interpretação do comportamento dos radiologistas durante a utilização do sistema, foram analisados os graus de certeza, observando o que levou a alterar algumas classificações previamente indicadas. Observou-se que 90% das mudanças na primeira classificação estavam relacionadas às imagens que o especialista não tinha certeza da classificação (taxa de confiança entre 0 e 2). A mudança mais significativa ocorreu nas imagens que os radiologistas estavam absolutamente incertos sobre o diagnóstico (passando de 10.77% para 3.51%), aumentando a taxa de confiança. Os demais níveis de certeza mostraram variação de aproximadamente 4%. Essa análise geral mostra o quanto os especialistas podem se beneficiar pelo apoio ao diagnóstico oferecido pelo sistema CBIR quando não há uma grande certeza na decisão tomada. Em algumas ocasiões extremas de dúvida no diagnóstico, como foi o caso das classificações de calcificação apresentadas acima, onde a taxa de acerto do médico diminuiu com o uso do sistema, há uma grande consideração naquilo que o sistema traz como sendo verdadeiro, independente do fato de o resultado do sistema estar correto ou não.

É importante ressaltar que cada iteração do processo representa cada contato do usuário com a imagem de consulta (inicialmente não diagnosticada) para efetivação da classificação. Na primeira iteração, os especialistas visualizaram a imagem e classificaram-na. Na segunda iteração, os radiologistas classificaram novamente a imagem após a realização da consulta por similaridade (ou seja, após o primeiro contato com o sistema). Nas próximas iterações, os especialistas aplicaram a realimentação por relevância para refinar a consulta para realizar novamente a classificação (análise) da imagem de referência.

Figura 30: Variação do “Grau de Certeza” dos médicos durante utilização do Sistema.

Em uma análise mais específica, visualizando cada classe separadamente nas diferentes iterações do processo de classificação, as variações nos graus de certeza do médico na própria classificação seguiu os padrões ilustrados nos gráficos da Figura 30 (a) e (b). Esses gráficos ilustram os resultados das modificações dos graus de certeza considerando imagens de massa e calcificação respectivamente. O eixo x desses gráficos representa cada iteração do processo. O gráfico da Figura 30(a), relativo às classificações de imagens contendo Massa, mostra que a maioria das modificações no grau de certeza ocorreu partindo dos graus 0 e 1 para os graus 2 e 4. Uma clara evidência de que o sistema, no geral, aumentou a confiança do médico em sua própria classificação. Por outro lado, analisando o gráfico da Figura 30(b), a confiança do médico na própria classificação diminuiu. Isso ocorre porque as características obtidas a partir de um histograma de níveis de cinza não descreve adequadamente as alterações visuais causadas por calcificação nas imagens, fazendo com que o resultado do sistema para esse tipo de lesão seja grandemente comprometido. Esse resultado reforça a importância de se definir bem o descritor de similaridade ideal para cada tipo de parâmetro perceptual. Um mesmo descritor para a base toda pode ser bom para um tipo de situação (p.ex. Massa), mas pode ser péssimo para imagens onde o achado apresenta um padrão visual tão diferente (p. ex. Calcificação). Este experimento corrobora a proposta de se trabalhar com as classes que compõem a base de imagens, conforme apresentado no Capítulo 5 desta tese.

7.3.3 Trabalho Colaborativo: Medida de Satisfação e usabilidade

Aproveitando toda a mobilização dos especialistas para a realização do experimento apresentado na seção anterior, foi realizado, em parceria com outra aluna, um trabalho colaborativo voltado para análise de satisfação e usabilidade do Sistema Higiiia (Souza 2012). O objetivo era coletar informações para elaborar um Modelo de Qualidade para desenvolvimento e avaliação de CBIR. Assim, após a finalização do processo diagnóstico com o uso do sistema, foi realizada uma entrevista com os radiologistas através do preenchimento de um questionário. O objetivo do questionário foi identificar as informações relevantes sobre as necessidades reais dos médicos, bem como as expectativas atingidas com o uso do sistema. Os dados coletados permitiram análises para avaliar a satisfação dos radiologistas ao utilizar o sistema na prática clínica. O questionamento era composto de seis perguntas de caráter pessoal (por exemplo: “Você já teve contato com esse tipo de sistema?”, entre outras) e 17 questões relativas à avaliação do sistema, elaboradas com base em características de usabilidade e funcionalidade do mesmo. A análise dos resultados da aplicação do questionário mostrou que:

- 67% dos usuários encontraram facilidade em operar o sistema, mesmo sendo o primeiro contato com esse tipo de sistema;
- 11% dos usuários tinham conhecimento prévio sobre a existência/aplicabilidade desse tipo de sistema;
- 44% dos usuários julgaram que a representação das imagens foi adequada para um diagnóstico inicial;
- 100% dos usuários sugeriram novas maneiras de facilitar a visualização das imagens;
- 89% dos usuários acreditam na aplicabilidade de Sistemas CBIR na prática clínica;
- 89% dos usuários indicariam o sistema para treinamento de radiologistas e estudantes de medicina durante a faculdade;

Durante a análise das funcionalidades e requisitos sugeridos pelos médicos foram identificadas algumas das reais necessidades dos radiologistas para viabilizar a utilização de sistemas CBIR. São elas:

- possibilidade de manipulação de imagem (contraste, zoom, visualização completa, marcadores de sinal, janelamento, entre outros),
- contar com telas de computador mais apropriadas para visualização de detalhes,
- integração do sistema com o PEP (Prontuário Eletrônico do Paciente) e o RIS (*Radiological Information System*) do Hospital para viabilizar todo o histórico médico do paciente.

As conclusões qualitativas, obtidas a partir dos resultados da aplicação do questionário, mostraram que os radiologistas têm grandes expectativas quanto à utilização de sistemas de busca por conteúdo na prática clínica. Há potencial interesse em tornar a ferramenta utilizável para recuperação de informações relevantes e para auxílio à tomada de decisões.

7.4 Considerações Finais

Neste capítulo foi apresentada uma análise de um sistema CBIR Médico, que é centrada no usuário, buscando suprir uma lacuna devido à pouca realização desse tipo de estudo/abordagem dentre os Sistemas CBIR desenvolvidos na área médica. Os resultados apresentados indicaram como um CBIR para a área médica pode operar em um ambiente clínico real, e como suas capacidades e limitações influenciam na tomada de decisão diagnóstica. A aplicação da metodologia proposta, baseada na análise das mudanças de classificação atreladas aos graus de certeza do médico na própria classificação, mostrou que o

diagnóstico médico é afetado tanto positivamente (quando o sistema funciona adequadamente) quanto negativamente (quando o sistema não recebe a calibração ideal para determinado padrão visual). Isso mostrou o quanto é necessária a continuidade de estudos que adequem os melhores descritores de similaridade para cada contexto específico de análise de imagens. O sistema, se bem ajustado com descritores de imagens representativos, pode guiar os especialistas para uma correta classificação além de aumentar a confiança do radiologista na própria classificação.

A metodologia proposta para avaliar o impacto e viabilidade clínica desse tipo de sistema permitiu medir a influência do sistema no diagnóstico realizado pelos especialistas. Além disso, as informações coletadas durante a interação do usuário com o sistema, como por exemplo quais imagens são relevantes dada uma certa imagem de consulta, poderão ser utilizadas em trabalhos futuros para destacar características importantes a serem consideradas no desenvolvimento de futuros sistemas de busca por conteúdo nessa área. Essas informações poderão trazer resultados mais próximos e consistentes com o desejo dos usuários.

Capítulo 8 - Conclusão

8.1 Considerações Finais

Os recentes trabalhos de pesquisa em sistemas CBIR têm evidenciado o potencial de uso de imagens similares como ferramenta de auxílio à tomada de decisão no processo diagnóstico. No entanto, a maior parte desses trabalhos ainda está restrita a domínios bastante específicos de conhecimento, dificultando a execução de uma avaliação realística da aplicabilidade desses sistemas como ferramenta de auxílio ao diagnóstico em um ambiente clínico real. Ao longo dos anos, obstáculos como a descontinuidade semântica, a generalização do sistema CBIR e a falta de estudos sobre a viabilidade clínica dessas ferramentas como forma de auxílio ao diagnóstico ainda persistem e também são responsáveis pela não efetivação real dessa tecnologia em ambientes médico-hospitalares em prática clínica. A necessidade de especialização do sistema para diminuir a descontinuidade semântica e a necessidade de generalização do mesmo para viabilizar seu uso em ambiente real criou um paradoxo difícil de ser contornado. Por isso, o sistema CBIR tem sido usado de modo reservado e em aplicações controladas. Tais sistemas precisam adquirir uma perspectiva centrada no usuário final para assim alcançar uma larga aceitação nos ambientes reais de diagnóstico por imagem. A inclusão da percepção médica na construção de ferramentas CBIR deverá aproximar essa tecnologia do especialista médico, quebrando uma barreira clara entre a ciência médica e a ciência da computação.

A proposta desta tese consistiu em promover a aproximação dos sistemas CBIR à realidade médica e assim aumentar a capacidade desses sistemas como Sistemas de Auxílio ao Diagnóstico (*Computer Aided Diagnosis - CAD*). A ideia principal foi desenvolver um arcabouço que permita o ajuste automático de consultas por similaridade baseado em parâmetros de percepção levantados pelos próprios radiologistas. Esse arcabouço possibilitará uma escolha automática de quais os parâmetros perceptuais deverão ser considerados relevantes no processamento da consulta. Toda essa contribuição teórica proposta na tese ajudou na construção de métodos que solucionam o paradoxo citado no parágrafo anterior. Apesar do abrangente estudo bibliográfico realizado nesta tese, não foi possível encontrar algum trabalho que faz uma contribuição nesse nível. Ou seja, de possibilitar a um Sistema CBIR ser específico a diversos contextos médicos e, ao mesmo tempo, incorporar métodos

que o tornam genérico a ponto de se tornarem viáveis de serem aplicados em um ambiente real. Assim, sistemas específicos poderão continuar sendo desenvolvidos e integrados à proposta desta tese, unificando assim vários algoritmos específicos em um grande sistema CBIR genérico o suficiente para adequação em ambientes de aplicação real. A Figura 31 ilustra as principais inovações apresentadas nesta tese, marcadas de vermelho, que caracterizam um CBIR Perceptual. Ela pode ser comparada com a Figura 11, que resume o que a maioria das propostas CBIR tradicionais da literatura apresentaram até a atualidade.

Figura 31: Visão Geral de um Sistema CBIR Perceptual

Outro ponto importante do trabalho foi a validação dos métodos propostos e do sistema CBIR desenvolvido. Nessa etapa foi realizado um estudo sobre o desempenho e a viabilidade de um sistema CBIR como ferramentas de auxílio ao diagnóstico em ambientes reais de diagnóstico por imagem. Foi observado o desempenho dos radiologistas ao avaliar um exame com o auxílio do sistema e por fim, questionários aplicados aos radiologistas indicaram quais tarefas devem ser acrescentadas aos sistemas CBIR para se tornarem uma ferramenta efetiva de auxílio ao diagnóstico. O projeto de pesquisa buscou suprir a descontinuidade semântica, propondo um mecanismo que aproxima o sistema CBIR ao nível de percepção do usuário médico, investigando e demonstrando sua aplicabilidade como

ferramenta de auxílio ao diagnóstico em um ambiente clínico real.

8.2 Principais Contribuições

Foram alcançadas contribuições teóricas e conceituais nas áreas de reconhecimento de padrões de imagens médicas, de uso de informações textual dos pedidos de exames e cabeçalho das imagens DICOM, de indexação das imagens baseada nas características extraídas e na recuperação de exames a partir do conteúdo pictórico e conteúdo semântico coletado junto aos especialistas dos contextos apresentados. Além da contribuição teórica para a área de conhecimento, os seguintes resultados foram obtidos como indicadores de produtividade:

- Desenvolvimento de um arcabouço teórico para aprimoramento de resultados de busca por similaridade em imagens médicas baseado nos conceitos de “Percepção Visual”. Foi proposto um algoritmo de “Definição automática de contextos”, aplicado já na etapa inicial de processamento de consultas, que possibilite a inclusão automática de conhecimento específico do domínio médico e a interação do usuário radiologista com os resultados da consulta por similaridade antes da realização da mesma.
- Desenvolvimento de uma taxonomia que indique quais os melhores descritores de similaridade que melhor represente um subconjunto de imagens seguindo a percepção do especialista médico. Tal taxonomia é de extrema importância para ampliar a usabilidade e aceitação de sistemas de recuperação de imagens por conteúdo.
- Adequação e criação de um novo modelo de dados para viabilizar o processamento de consultas por similaridade que permitam contemplar a percepção de similaridade do ser humano e a escolha automática de “Parâmetros de Percepção”.
- Desenvolvimento de novos extratores de características específicos ao contexto, bem como o desenvolvimento de uma nova representação de imagens de coluna vertebral visando a construção de um CBIR Perceptual
- Desenvolvimento de uma ferramenta CBIR estruturada e modular (o Higiia), que permite inclusão contínua de novos algoritmos de processamento, extração e seleção de características e recuperação por conteúdo.
- Uma pesquisa/análise sobre a viabilidade da ferramenta desenvolvida ao ser utilizada em um ambiente real, bem como sua aplicabilidade como ferramenta de auxílio ao

diagnóstico e ensino médico.

Os resultados alcançados contemplaram aspectos de pesquisa muito relevantes para a área de recuperação de imagens médicas e consultas por similaridade. Esses resultados apresentam soluções novas para problemas que têm sido pesquisados pelas comunidades de pesquisa em CBIR.

8.3 Publicações Geradas

As publicações geradas até o momento foram:

8.3.1. Publicações em Periódicos

- a) **PRoSPer: Perceptual similarity queries in medical CBIR systems through user profiles.** Pedro H. Bugatti, Daniel S. Kaster, Marcelo Ponciano-Silva, Caetano Traina Jr., Paulo M. Azevedo-Marques, Agma J.M. Traina; Computers in Biology and Medicine, Volume 45, 1 February 2014, Pages 8-19, ISSN 0010-4825, 2013.

8.3.2. Publicações em Conferências com Arbitragem

- b) **Does a CBIR system really impact decisions of physicians in a clinical environment?.** Ponciano-Silva, M.; Souza, J.; Bugatti, P.H.; Bedo, M.V.N.; Kaster, D.S.; Braga, R.T.V.; Bellucci, A.D.; Azevedo-Marques, P.M.; Traina-Jr.,C.; Traina, A.J.M.; In: 2013 IEEE 26th International Symposium on ComputerBased Medical Systems (CBMS), 2013, Porto. Proceedings of the 26th IEEE International Symposium on Computer-Based Medical Systems. v. 1. p. 41-46.
- c) **A Differential Method for Representing Spinal MRI for Perceptual-CBIR.** Ponciano-Silva, M.; Bugatti, P.H.; Reis, R.M.; Azevedo-Marques, P.M.; Nogueira-Barbosa, M.; Traina-Jr.,C.; Traina, A.J.M.; In: 18th Iberoamerican Congress on Pattern Recognition (CIARP), 2013, Havana, Cuba. Lecture Notes In Computer Science Series, 2013. p. 1-6.
- d) **Using boundary conditions for combining multiple descriptors in similarity based queries.** Barroso, R.F.; Ponciano-Silva, M.; Traina, A.J.M.; Bueno, R.; In: 18th Iberoamerican Congress on Pattern Recognition (CIARP), 2013, Havana, Cuba. Lecture Notes In Computer Science Series, 2013. p. 1-8.
- e) **Pattern recognition of diffuse lung disease in HRCT for content-based image retrieval and computer-aided diagnosis.** Calabrez, L.; Ponciano-Silva, Marcelo; Azevedo-Marques, P. M. . In: CARS 2013 - Computer Assisted Radiology and Surgery, 2013, Heidelberg. Proceedings of the 27th International Congress and Exhibition, 2013. v. 8. p. S338-S339

- f) **Higiia: A Perceptual Medical CBIR System Applied to Mammography Classification.** Bedo, M.V.N.; Ponciano-Silva, M.; Bugatti, P.H.; Kaster, D.S.; Azevedo-Marques, P.M.; Traina-Jr.,C.; Traina, A.J.M.; In: Demo and Applications Session of the XXVII Brazilian Symposium on Databases (SBB D), 2012, São Paulo - SP. Proceedings of the SBB D 2012. Porto Alegre: SBC - Brazilian Computer Society, 2012. p. 13-18.
- g) **Integrating User Profile in Medical CBIR Systems to Answer Perceptual Similarity Queries.** Bugatti, P.H.; Ponciano-Silva, M.; Kaster, D.S.; Traina-Jr.,C.; Traina, A.J.M.; In: SPIE Medical Imaging Conference, 2011, Lake Buena Vista, Orlando, USA. Proceedings of the SPIE Medical Imaging 2011. Los Angeles: SPIE, 2011. v. 1. p. 1-12.
- h) **MedFMI-SiR: A Powerful DBMS Solution for Large-Scale Medical Image Retrieval.** Kaster, D.S.; Ponciano-Silva, M.; Bugatti, P.H.; Traina-Jr.,C.; Traina, A.J.M.; In: 2nd International Conference on Information Technology in Bio- and Medical Informatics (ITBAM), 2011, Toulouse, FR. Lecture Notes in Computer Science (LNCS). Berlin / Heidelberg: Springer, 2011. v. 6865. p. 16-30.
- i) **A Proposal of a Reference Model for the Assessment of Content-Based Medical Image Retrieval Systems focused on Computer-Aided Diagnosis Applications.** Souza, J. P.; Ponciano-Silva, Marcelo; Bugatti, P. H. ; Traina, A. J. M.; Braga, R. T.; Azevedo-Marques, P. M. .In: 8th Annual Health Technology Assessment International (HTAi) Meeting, 2011, Rio de Janeiro. HTA for Health Systems Sustainability, 2011
- j) **Integrating User Preference to Similarity Queries over Medical Images Datasets** Ferreira, M. R. P. ; Ponciano-Silva, Marcelo ; Amo, Sandra Aparecida de ; Pereira, F. S. F. ; Traina, A. J. M. ; Traina-Jr, Caetano ; Chbeir, R.. In: 23rd International Symposium on Computer-Based Medical Systems (CBMS 2010), 2010, Perth. Proceedings of the CBMS 2010, v. 1. p. 1-6.
- k) **OBERON: Integrando os Módulos PEP, Visualizador de Imagens Médicas e CAD de um Sistema de Informação de Saúde** Bedo, Marcos Vinícius Naves; Ponciano-Silva, Marcelo. In: Congresso Brasileiro de Informática em Saúde, 2010, Porto de Galinhas. Anais do XII CBIS, 2010. v. 1. p. 1-6.

8.4 Propostas para Trabalhos Futuros

A seguir estão apresentadas algumas sugestões de tópicos que podem ser abordados em trabalhos futuros.

- Refazer experimento prático de viabilidade clínica do CBIR em ambiente real considerando a nova abordagem proposta na tese, incluindo parâmetros de percepção e definição automática de contextos na ferramenta utilizada pelo radiologista.
- Desenvolvimento de técnicas para recuperação de imagens médicas 3D, criando o conceito de consultas baseada em exames de consulta (e não apenas imagem de

consulta);

- Desenvolvimento de novos extratores de características específicos aos principais contextos de imagens médicas;
- Aplicação de algoritmos de detecção de lesões e reconhecimento de padrões para guiar consultas por similaridade;
- Exploração de novas técnicas para avaliação de descritores de similaridade, bem como análise da interferência de operações como normalização local e global no desempenho de extratores de características;
- Desenvolvimento de novas técnicas de visualização de informações voltadas para a análise perceptual das características de baixo nível utilizadas na representação de conteúdo visual em imagens;

REFERÊNCIAS

- Abe, H. et al., 2004. Artificial neural networks (ANNs) for differential diagnosis of interstitial lung disease: results of a simulation test with actual clinical cases. *Academic Radiology*, 11, pp.29–37.
- Akgül, C.B. et al., 2011. Content-based image retrieval in radiology: current status and future directions. *Journal of digital imaging*, 24(2), pp.208–22. Available at: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3056970&tool=pmcentrez&rendertype=abstract> [Accessed January 20, 2014].
- Alexandre, D.S. & Tavares, J.M.R.S., 2007. Factores da Percepção Visual Humana na Visualização de Dados. In *CMNE/CILAMCE*. Porto, Portugal: APMTAC.
- Alexandrini, F., Bortoluzzi, M.K. & Wangenheim, A. V., 2005. Improving Content Based Recovery on a Radiological Reports Database. In K.-D. Althoff et al., eds. *Conference Professional Knowledge Management - Experiences and Visions*. Kaiserslautern, Germany: DFKI, Kaiserslautern, pp. 309–315.
- Alto, H., Rangayyan, R.M. & Desautels, J.E.L., 2005. Content-based retrieval and analysis of mammographic masses. *Journal of Electronic Imaging*, 14(2), pp.1–17.
- Aman, J., Yao, J. & Summers, R.M., 2009. Reducing the false positive rate of computer aided detection for CT colonography using Content Based Image Retrieval. In *2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro*. Boston, MA: IEEE, pp. 915–918. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5193202> [Accessed August 26, 2010].
- Andrade, F.S.P. et al., 2012. Fusion of Local and Global Descriptors for Content-Based Image and Video Retrieval. In *CIARP*. pp. 845–853.
- Antani, S. et al., 2002. A Biomedical Information System for Combined Content-Based Retrieval of Spine X-ray Images and Associated Text Information. , pp.16–18. Available at: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.12.1046>.
- Antani, S. et al., 2004. Evaluation of shape similarity measurement methods for spine X-ray images. *Journal of Visual Communication and Image Representation*, 15(3), pp.285–302. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S1047320304000367> [Accessed January 15, 2014].
- Antani, S., Long, R. & Thomas, G.R., 2008. Bridging the Gap: Enabling CBIR in Medical Applications. In *21st IEEE International Symposium on Computer-Based Medical Systems*.
- Arimura, H. et al., 2009. Computer-Aided Diagnosis Systems for Brain Diseases in Magnetic Resonance Images. *Algorithms*, 2(3), pp.925–952. Available at: <http://www.mdpi.com/1999-4893/2/3/925/>.

- Armato, S.G. et al., 2003. Automated lung nodule classification following automated nodule detection on CT: a serial approach. *Medical physics*, 30(6), pp.1188–97. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/12852543>.
- Azevedo-Marques, P.M. et al., 2008. Reducing the semantic gap in content-based image retrieval in mammography with relevance feedback and inclusion of expert knowledge. *International Journal of Computer Assisted Radiology and Surgery*, 3(1-2), pp.123–130. Available at: <http://www.springerlink.com/content/f9164t3k77u75232>.
- Azevedo-Marques, P.M. De et al., 2005. Integração RIS/PACS no Hospital das Clínicas de Ribeirão Preto: uma solução baseada em “web.” *Radiologia Brasileira*, 38(1), pp.37–43.
- Azevedo-Marques, P.M. de & Rangayyan, R.M., 2013. Content-based Retrieval of Medical Images: Landmarking, Indexing, and Relevance Feedback. *Synthesis Lectures on Biomedical Engineering*, 8(1), pp.1–143. Available at: <http://www.morganclaypool.com/doi/abs/10.2200/S00469ED1V01Y201301BME048> [Accessed January 24, 2014].
- Bai, B. et al., 2007. fMRI Brain Image Retrieval Based on ICA Components. *ENC*, pp.10–17. Available at: <http://portal.acm.org/citation.cfm?id=1302883> [Accessed June 24, 2010].
- Balan, A.G.R. et al., 2005. Fractal Analysis of Image Textures for Indexing and Retrieval by Content. In *18th IEEE Intl. Symposium on Computer-Based Medical Systems - CBMS*. Dublin, Ireland: IEEE Computer Society, p. 6 pags.
- Balan, A.G.R. et al., 2007. HEAD: the Human Encephalon Automatic Delimiter. In *20th IEEE Intl Symposium on Computer-Based Medical Systems (CBMS 2007)*. Maribor, Slovenia: IEEE Computer Society, p. 6p.
- Bannour, H., Hlaoua, L. & el Ayeb, B., 2009. Survey of the Adequate Descriptor for Content-Based Image Retrieval on the Web: Global versus Local Features. In *CORIA*. pp. 445–456.
- Barb, A.S., Shyu, C.-R. & Sethi, Y.P., 2005. Knowledge representation and sharing using visual semantic modeling for diagnostic medical image databases. *IEEE transactions on information technology in biomedicine: a publication of the IEEE Engineering in Medicine and Biology Society*, 9(4), pp.538–53. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/16379371>.
- Barioni, M.C.N. et al., 2006. SIREN: A similarity Retrieval Engine for Complex Data. In *32nd Intl Conference on Very Large Data Bases (VLDB 06)*. Seoul, South Korea: ACM Press, pp. 1155–1158.
- Bedo, M.V.N. et al., 2012. Higiia: A Perceptual Medical CBIR System Applied to Mammography Classification. In *Demo and Applications Session of the XXVII Brazilian Symposium on Databases (SBBD)*. São Paulo, SP: SBC - Brazilian Computer Society, pp. 13–18. Available at: <http://data.ime.usp.br/sbbd2012/application/01.html>.

- Bedo, M.V.N., 2013. *Incluindo funções de distância e extratores de características para suporte a consultas por similaridade*. Dissertação de Mestrado. Universidade de São Paulo.
- Beecks, C., Kirchhoff, S. & Seidl, T., 2013. Signature matching distance for content-based image retrieval. In *Proceedings of the 3rd ACM conference on International conference on multimedia retrieval - ICMR '13*. New York, New York, USA: ACM Press, p. 41. Available at: <http://dl.acm.org/citation.cfm?doid=2461466.2461474> [Accessed January 24, 2014].
- Bellazzi, R. & Zupan, B., 2008. Predictive data mining in clinical medicine: current issues and guidelines. *International journal of medical informatics*, 77(2), pp.81–97. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/17188928>.
- Bueno, J.M., 2002. *Suporte à Recuperação de Imagens Médicas baseada em Conteúdo através de Histogramas Métricos*. Tese de Doutorado. Universidade de São Paulo.
- Bueno, R. et al., 2009. Unsupervised scaling of multi-descriptor similarity functions for medical image datasets. In *2009 22nd IEEE International Symposium on Computer-Based Medical Systems*. IEEE, pp. 1–8. Available at: http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=5255275.
- Bugatti, H.P., Traina, A.J.M. & Traina Caetano, J., 2008. A New Method to Efficiently Reducing Histogram Dimensionality. In *Symposium on Medical Imaging (SPIE-2008), Computer-Aided Diagnosis track*. San Diego - CA, p. 4 pags., to be published.
- Bugatti, P.H., 2008. *Análise da influência de funções de distância para o processamento de consultas por similaridade em recuperação de imagens por conteúdo*. Dissertação de Mestrado. Universidade de São Paulo.
- Bugatti, P.H. et al., 2009. Content-based retrieval of medical images: From context to perception. In *2009 22nd IEEE International Symposium on Computer-Based Medical Systems*. IEEE, pp. 1–8.
- Bugatti, P.H. et al., 2014. PRoSPer: Perceptual similarity queries in medical CBIR systems through user profiles. *Computers in Biology and Medicine*, 45, pp.8–19. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S0010482513003442> [Accessed January 8, 2014].
- Burkhard, H.-D., 2004. Case Competition and Similarity in Case-Based Reasoning. *Computer Science and Information Systems*, 1(2), pp.27–55.
- Carélo, C.C.M. et al., 2011. Slicing the metric space to provide quick indexing of complex data in the main memory. *Information Systems*, 36(1), pp.79–98. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S030643791000058X> [Accessed January 24, 2014].
- Chan, T. & Huang, H.K., 2008. Effect of a computer-aided diagnosis system on clinicians' performance in detection of small acute intracranial hemorrhage on computed

- tomography. *Academic radiology*, 15(3), pp.290–9. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/18280927>.
- Chbeir, R., Amghar, Y. & Flory, A., 2000. MIMS: A Prototype for medical image retrieval. In J.-J. Mariani & D. Harman, eds. *Recherche d'Information Assistée par Ordinateur - RIAO*. CID, pp. 846–861.
- Chen, C.-S., Yeh, C.-W. & Yin, P.-Y., 2009. A novel Fourier descriptor based image alignment algorithm for automatic optical inspection. *Journal of Visual Communication and Image Representation*, 20(3), pp.178–189. Available at: <http://dx.doi.org/10.1016/j.jvcir.2008.11.003>.
- Chen, Y. et al., 2013. iLike: Bridging the Semantic Gap in Vertical Image Search by Integrating Text and Visual Features. *IEEE Transactions on Knowledge and Data Engineering*, 25(10), pp.2257–2270. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6378368> [Accessed January 24, 2014].
- Cheng, P.-C. et al., 2005. SMIRE: Similar Medical Image Retrieval Engine. In *Lecture Notes In Computer Science - Multilingual Information Access for Text, Speech and Images*. Springer Berlin / Heidelberg, pp. 750–760.
- Chronaki, C.E., Zabulis, X. & Orphanoudakis, S.C., 1997. I2Cnet medical image annotation service. *Medical informatics = Médecine et informatique*, 22(4), pp.337–47. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/9509404> [Accessed June 24, 2010].
- Chu, W., 1995. KMeD: A knowledge-based multimedia medical distributed database system. *Information Systems*, 20(2), pp.75–96. Available at: <http://linkinghub.elsevier.com/retrieve/pii/030643799598556S> [Accessed June 24, 2010].
- Chu, W.W. et al., 1998. Knowledge-based image retrieval with spatial and temporal constructs. *IEEE transactions on knowledge and data engineering Y*, 10(6), pp.872–888. Available at: <http://www.refdoc.fr/Detailnotice?idarticle=14345979> [Accessed June 24, 2010].
- Chupin, M. et al., 2009. Fully automatic hippocampus segmentation and classification in Alzheimer's disease and mild cognitive impairment applied on data from ADNI. *Hippocampus*, 19(6), pp.579–87. Available at: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=2837195&tool=pmcentrez&rendertype=abstract>.
- Ciaccia, P., Patella, M. & Zezula, P., 1997. M-tree: An efficient access method for similarity search in metric spaces. In M. Jarke, ed. *International Conference on Very Large Databases (VLDB)*. Athens, Greece: Morgan Kaufmann, pp. 426–435.
- Cordeiro, R.L.F., Faloutsos, C. & Traina Júnior, C., 2013. *Data Mining in Large Sets of Complex Data*, London: Springer London. Available at: <http://link.springer.com/10.1007/978-1-4471-4890-6> [Accessed January 24, 2014].

- Cortes, C. & Vapnik, V., 1995. Support-vector networks. *Machine Learning*, 20(3), pp.273–297. Available at: <http://www.springerlink.com/content/k238jx04hm87j80g>.
- Costa, L.F. da & Jr., R.M.C., 2001. *Shape Analysis and Classification - Theory and Practice*, Boca Raton, CA: CRC Press.
- Coustaty, M. et al., 2011. Using Ontologies to Reduce the Semantic Gap between Historians and Image Processing Algorithms. In *2011 International Conference on Document Analysis and Recognition*. IEEE, pp. 156–160. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6065295> [Accessed January 24, 2014].
- Datta, R. et al., 2008. Image Retrieval: Ideas, influences and trends of the new age. *ACM Comput. Surv.*, 40-2(5), p.60.
- Depeursinge, A. et al., 2012. Case-based lung image categorization and retrieval for interstitial lung diseases: clinical workflows. *International journal of computer assisted radiology and surgery*, 7(1), pp.97–110. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/21629982> [Accessed January 20, 2014].
- Depeursinge, A. et al., 2008. Lung Tissue Classification in HRCT data Integrating the Clinical Context. In *21st IEEE International Symposium on Computer-Based Medical Systems*.
- Depeursinge, A. et al., 2011. Prototypes for content-based image retrieval in clinical practice. *The open medical informatics journal*, 5(Suppl 1), pp.58–72. Available at: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3149811&tool=pmcentrez&rendertype=abstract> [Accessed January 20, 2014].
- Deselaers, T. et al., 2006. FIRE in ImageCLEF 2005: Combining Content-Based Image Retrieval with Textual Information Retrieval. In *Lecture Notes in Computer Science*.
- Deselaers, T., Keysers, D. & Ney, H., 2008. Features for image retrieval: an experimental comparison. *Information Retrieval*, 11(2), pp.77–107.
- Deserno, T. et al., 2011. Towards Computer-Aided Diagnostics of Screening Mammography Using Content-Based Image Retrieval. In *2011 24th SIBGRAPI Conference on Graphics, Patterns and Images*. IEEE, pp. 211–219. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6134754> [Accessed January 20, 2014].
- Deserno, T.M. et al., 2008. Extended Query Refinement for Medical Image Retrieval. *Journal of Digital Imaging*, 21(3), pp.280–289.
- Deserno, T.M., Antani, S. & Long, R., 2007. Gaps in Content-Based Image Retrieval. In *Medical Imaging 2007: PACS and Imaging Informatics*. SPIE - The International Society for Optical Engineering, p. 65160J.
- Deserno, T.M., Antani, S. & Long, R., 2009. Ontology of Gaps in Content-Based Image Retrieval. *Journal of Digital Imaging*, 22(2), pp.202–215.

- Deserno, T.M., Welter, P. & Horsch, A., 2012. Towards a repository for standardized medical image and signal case data annotated with ground truth. *Journal of digital imaging*, 25(2), pp.213–26. Available at: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3295968&tool=pmcentrez&rendertype=abstract> [Accessed January 24, 2014].
- Doi, K., 2007. Computer-aided diagnosis in medical imaging: historical review, current status and future potential. *Computerized medical imaging and graphics : the official journal of the Computerized Medical Imaging Society*, 31(4-5), pp.198–211. Available at: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=1955762&tool=pmcentrez&rendertype=abstract>.
- Doi, K., 2005. Current status and future potential of computer-aided diagnosis in medical imaging. *Br J Radiol*, 78(suppl_1), pp.S3–19.
- Doi, K., 2006. Diagnostic Imaging over the last 50 years: research and development in medical imaging science and technology. *Phys Med Biol*, 51(13), pp.5–27.
- Donovana, T., Manning, D.J. & Crawford, T., 2008. Performance changes in lung nodule detection following perceptual feedback of eye movements. In *Medical Imaging 2008: Image Perception, Observer Performance, and Technology Assessment*. Proceedings of SPIE.
- Dougherty, G., 2009. *Digital Image Processing for Medical Applications*, Cambridge University Press. Available at: <http://www.amazon.com/Digital-Image-Processing-Medical-Applications/dp/0521860857>.
- Doulamis, N. & Doulamis, A., 2006. Evaluation of relevance feedback schemes in content-based in retrieval systems☆. *Signal Processing: Image Communication*, 21(4), pp.334–357. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S0923596505001360> [Accessed July 29, 2010].
- Eakins, J. & Graham, M., 1999. *Content-based image retrieval*,
- Faria, F.F. et al., 2010. Learning to rank for content-based image retrieval. In *International Multimedia Conference*. Philadelphia, Pennsylvania, USA: ACM New York, NY, USA, pp. 285–294. Available at: <http://portal.acm.org/citation.cfm?doid=1743384.1743434>.
- Felipe, J.C., 2005. *Desenvolvimento de métodos para extração, comparação e análise de características intrínsecas de imagens médicas, visando à recuperação perceptual por conteúdo*. Tese de Doutorado. Universidade de São Paulo.
- Felipe, J.C., Ribeiro, M.X., et al., 2006. Effective Shape-based Retrieval and Classification of Mammograms. In *21th ACM Symposium on Applied Computing (SAC)*. Dijon, France: ACM Press, pp. 250–255.
- Felipe, J.C., Traina, A.J.M. & Traina Caetano, J., 2006. A New Similarity Measure for Histograms Applied to Content-based Retrieval of Medical Images. In *21th ACM Symposium on Applied Computing (SAC)*. Dijon, France: ACM Press, pp. 258–259.

- Felipe, J.C., Traina, C. & Traina, A.J.M., 2009. A new family of distance functions for perceptual similarity retrieval of medical images. *Journal of digital imaging : the official journal of the Society for Computer Applications in Radiology*, 22(2), pp.183–201. Available at: <http://www.springerlink.com/content/3308jjh136768364>.
- Filardi, A.L. & Traina, A.J.M., 2008. Combinação de Técnicas de Interação Humano-Computador para Avaliação de Sistemas de Recuperação de Imagens por Conteúdo. In *XIV Simpósio Brasileiro de Sistemas Multimedia e Web (WebMedia 2008)*. Vila Velha, ES.: SBC, pp. 170–177.
- Fischer, B., Deserno, T.M., et al., 2008. Integration of a Research CBIR System with RIS and PACS for Radiological Routine. In K. P. Andriole & K. M. Siddiqui, eds. *Medical Imaging 2008: PACS and Imaging Informatics*. SPIE - The International Society for Optical Engineering.
- Fischer, B., Sauren, M., et al., 2008. Scene Analysis with Structural Prototypes for Content-Based Image Retrieval in Medicine. In *Medical Imaging 2008: Image Processing*. Proceedings of SPIE.
- Freer, T.W. & Ulissey, M.J., 2001. Screening mammography with computer-aided detection: prospective study of 12,860 patients in a community breast center. *Radiology*, 220(3), pp.781–6. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/11526282>.
- French, J.C., Jin, X. & Martin, W.N., 2004. An Empirical Investigation of the Scalability of a Multiple Viewpoint CBIR System. *Image and Video Retrieval*, p.2051. Available at: <http://www.springerlink.com/content/ptv2gcu26bpfqpha> [Accessed July 29, 2010].
- Fukushima, A. et al., 2004. Application of an artificial neural network to high-resolution CT: usefulness in differential diagnosis of diffuse lung disease. *AJR. American journal of roentgenology*, 183(2), pp.297–305. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/15269016>.
- Furuie, S.S. et al., 2007. Managing Medical Images and Clinical Information: inCor's Experience. *IEEE Transactions on Information Technology in Biomedicine*, 11(1), pp.17–24.
- Genant, H.K. et al., 1993. Vertebral fracture assessment using a semiquantitative technique. *Journal of bone and mineral research : the official journal of the American Society for Bone and Mineral Research*, 8(9), pp.1137–48. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/8237484> [Accessed January 20, 2014].
- Gerhardinger, L.C., 2006. *Segmentação de imagens e validação de classes por abordagem estocástica*. Dissertação de Mestrado. Universidade de São Paulo.
- Giger, M.L., 2002. Intelligent CAD workstation for breast imaging using similarity to known lesions and multiple visual prompt aids. In *Proceedings of SPIE*. SPIE, pp. 768–773. Available at: <http://link.aip.org/link/?PSI/4684/768/1&Agg=doi>.

- Gomes, J. & Mojsilovic, A., 2002. Semantic based categorization, browsing and retrieval in medical image databases. In *Image Processing. 2002. Proceedings. 2002 International Conference on (3)*. pp. 145–148.
- Gonzalez, R.C. & Woods, R.E., 2008. *Digital Image Processing* 3rd ed., Prentice Hall.
- Guld, M.O. et al., 2007. A generic concept for the implementation of medical image retrieval systems. *International Journal of Medical Informatics*, 76(2-3), pp.252–259.
- Guldogan, E. & Gabbouj, M., 2009. Dynamic feature weights with relevance feedback in content-based image retrieval. In *2009 24th International Symposium on Computer and Information Sciences*. IEEE, pp. 56–59. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5291921> [Accessed January 24, 2014].
- Gutierrez, M.A., 2011. Sistemas de Informação Hospitalares: progressos e Avanços (Editorial). *Journal of Health Informatics*, 3(2), pp.I–II.
- Hadjidemetriou, E., Grossberg, M.D. & Nayar, S.K., 2004. Multiresolution Histograms and Their Use for Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 26(7), pp.831–847.
- Hadjiiski, L. et al., 2012. Inter- and Intra-Observer Variability of Radiologists Evaluating CBIR Systems. In A. D. A. Maidment, P. R. Bakic, & S. Gavenonis, eds. *Breast Imaging*. Springer Berlin Heidelberg, pp. 482–489 (7361). Available at: http://dx.doi.org/10.1007/978-3-642-31271-7_62.
- Haralick, R.M., Shanmugam, K. & Dinstein, I., 1973. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3, pp.610–621.
- Hoi, C.-H. & Lyu, M.R., 2004. A novel log-based relevance feedback technique in content-based image retrieval. In *Proceedings of the 12th annual ACM international conference on Multimedia - MULTIMEDIA '04*. New York, New York, USA: ACM Press, p. 24. Available at: <http://portal.acm.org/citation.cfm?doid=1027527.1027533> [Accessed January 8, 2014].
- Hota, R.N., Syed, S. & Krishna, P.R., 2010. Local-feature-based image retrieval with weighted relevance feedback. *International Journal of Business Intelligence and Data Mining*, 5(4), p.353. Available at: <http://www.inderscience.com/link.php?id=36124> [Accessed January 24, 2014].
- Houssami, N., Given-Wilson, R. & Ciatto, S., 2009. Early detection of breast cancer: overview of the evidence on computer-aided detection in mammography screening. *Journal of medical imaging and radiation oncology*, 53(2), pp.171–6. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/19527363>.
- Hsu, W. et al., 2009a. SPIRS: a Web-based image retrieval system for large biomedical databases. *International journal of medical informatics*, 78 Suppl 1, pp.S13–24. Available at:

<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=2693318&tool=pmcentrez&rendertype=abstract>.

- Hsu, W. et al., 2009b. SPIRS: a Web-based image retrieval system for large biomedical databases. *International journal of medical informatics*, 78 Suppl 1, pp.S13–24. Available at: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=2693318&tool=pmcentrez&rendertype=abstract>.
- Huang, J. et al., 2013. Integration of PACS and CAD systems using DICOMDIR and open-source tools. In M. Y. Law & W. W. Boonn, eds. p. 86740V. Available at: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2001560> [Accessed January 21, 2014].
- Huang, P.-W. & Dai, S.K., 2003. Image retrieval by texture similarity. *Pattern Recognition Letters*, 36(3), pp.665–679.
- Huang, Z. et al., 2008. Locality condensation: a new dimensionality reduction method for image retrieval. In *Proceeding of the 16th ACM international conference on Multimedia - MM '08*. New York, New York, USA: ACM Press, p. 219. Available at: <http://portal.acm.org/citation.cfm?doid=1459359.1459389> [Accessed January 24, 2014].
- Huber, M.B. et al., 2010. Classification of interstitial lung disease patterns with topological texture features. In N. Karssemeijer & R. M. Summers, eds. *Medical Imaging 2010: Computer-Aided Diagnosis*. San Diego, California, USA: SPIE, pp. 762410–8. Available at: <http://link.aip.org/link/?PSI/7624/762410/1>.
- Jaimes, A., Sebe, N. & Gatica-Perez, D., 2006. Human-centered computing: A multimedia perspective. In *Special Session on Human-Centered Multimedia*. Proceedings of the ACM International Conference on Multimedia.
- Jan, Jiri & Jan, Jiří, 2005. *Medical image processing, reconstruction, and restoration: concepts and methods*, CRC Press. Available at: <http://books.google.com/books?id=V5rDNQ-ZY9MC&pgis=1>.
- Jeong, S., Kim, S.-W. & Choi, B.-U., 2009. Dimensionality reduction for similarity search with the Euclidean distance in high-dimensional applications. *Multimedia Tools and Applications*, 42(2), pp.251–271. Available at: <http://www.springerlink.com/index/10.1007/s11042-008-0243-y>.
- Jin, H. et al., 2007. Content and semantic context based image retrieval for medical image grid. In *2007 8th IEEE/ACM International Conference on Grid Computing*. IEEE, pp. 105–112. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4354122>.
- Kalpana, J. & Krishnamoorthy, R., 2012. Generalized adaptive Bayesian Relevance Feedback for image retrieval in the Orthogonal Polynomials Transform domain. *Signal Processing*, 92(12), pp.3062–3067. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S0165168412001594> [Accessed January 24, 2014].

- Kalpathy-Cramer, J. & Hersh, W., 2010. Multimodal medical image retrieval: image categorization to improve search precision. In *International Multimedia Conference*. Philadelphia, Pennsylvania, USA: ACM New York, NY, USA, pp. 165–174. Available at: <http://portal.acm.org/citation.cfm?doid=1743384.1743415>.
- Kasai, S. et al., 2008. Usefulness of computer-aided diagnosis schemes for vertebral fractures and lung nodules on chest radiographs. *AJR. American journal of roentgenology*, 191(1), pp.260–5. Available at: <http://www.ajronline.org/cgi/content/abstract/191/1/260>.
- Kass, M., Witkin, A. & Terzopoulos, D., 1988. Snakes: Active contour models. *International Journal of Computer Vision*, 1(4), pp.321–331. Available at: <http://www.springerlink.com/content/q7g93335q86604x6>.
- Kaster, D. dos S. et al., 2011. MedFMI-SiR: A Powerful DBMS Solution for Large-Scale Medical Image Retrieval. In *2nd International Conference on Information Technology in Bio- and Medical Informatics (ITBAM)*, Toulouse, FR. Berlin/Heidelberg: Springer, pp. 16–30.
- Kim, R. et al., 2010. An investigation into the relationship between semantic and content based similarity using LIDC. In *International Multimedia Conference*. Philadelphia, Pennsylvania, USA: ACM New York, NY, USA, pp. 185–192. Available at: <http://portal.acm.org/citation.cfm?doid=1743384.1743417>.
- Korn, P. et al., 1998. Fast and effective retrieval of medical tumor shapes. *IEEE Transactions on Knowledge and Data Engineering*, 10(6), pp.889–904. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=738356>.
- Kumar, A. et al., 2013. Content-based medical image retrieval: a survey of applications to multidimensional and multimodality data. *Journal of digital imaging*, 26(6), pp.1025–39. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/23846532> [Accessed January 20, 2014].
- Kumaran, N. & Bhavani, R., 2012. Spine MRI Image Retrieval using Texture Features. *International Journal of Computer Applications*, 46(24), pp.1–7.
- Kumazawa, S. et al., 2008. An investigation of radiologists' perception of lesion similarity: observations with paired breast masses on mammograms and paired lung nodules on CT images. *Academic radiology*, 15(7), pp.887–94. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/18572125> [Accessed January 8, 2014].
- Lam, M. et al., 2007. Content-based image retrieval for pulmonary computed tomography nodule images. In *Proceedings of SPIE*. SPIE, p. 65160N–65160N–12. Available at: <http://link.aip.org/link/PSISDG/v6516/i1/p65160N/s1&Agg=doi>.
- Lehmann, T.M. et al., 2006. IRMA - A content-based approach to Image Retrieval in Medical Applications. In M. Khosrow-Pour, ed. *Information Resources Management Association International Conference*. pp. 911–912.

- Lehmann, T.M., Guld, M.O. & Thies, C., 2003. Content-based Image Retrieval in Medical Applications for Picture Archiving and Communication Systems. In *SPIE 2003. Proceedings of SPIE*, pp. 440–451.
- Li, J. & Allinson, N.M., 2013. Relevance Feedback in Content-Based Image Retrieval: A Survey. In M. Bianchini, M. Maggini, & L. C. Jain, eds. *Handbook on Neural Information Processing: Intelligent Systems Reference Library*. Springer Berlin Heidelberg, p. (49) 433–469.
- Li, Q. et al., 2003. Investigation of new psychophysical measures for evaluation of similar images on thoracic computed tomography for distinction between benign and malignant nodules. *Medical physics*, 30(10), pp.2584–93. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/14596294>.
- Liu, C.-T. et al., 2001. A content based CT lung retrieval system for assisting differential diagnosis image collection. In *International Conference on Multimedia and Exposition*. Tokyo, Japan: IEEE Computer Society, pp. 241–244.
- Liu, H. et al., 2008. Comparing dissimilarity measures for content-based image retrieval. *Lecture Notes In Computer Science*, pp.44–50. Available at: <http://portal.acm.org/citation.cfm?id=1786381> [Accessed June 23, 2010].
- Liu, Y. et al., 2007. A Survey of Content-based Image Retrieval with High-level Semantics. *Pattern Recognition Letters*, 40, pp.262–282.
- Long, L.R. et al., 2009. Content-Based Image Retrieval in Medicine: Retrospective Assessment, State of the Art, and Future Directions. *International journal of healthcare information systems and informatics : official publication of the Information Resources Management Association*, 4(1), pp.1–16. Available at: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=2879660&tool=pmcentrez&rendertype=abstract>.
- Lötjönen, J.M. et al., 2010. Fast and robust multi-atlas segmentation of brain magnetic resonance images. *NeuroImage*, 49(3), pp.2352–65. Available at: <http://dx.doi.org/10.1016/j.neuroimage.2009.10.026>.
- Malcok, M., Aslandogan, Y. & Yesildirek, A., 2006. Fractal Dimension and Similarity Search in High-Dimensional Spatial Databases. In *2006 IEEE International Conference on Information Reuse & Integration*. IEEE, pp. 380–384. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4018521>.
- Malik, F. & Baharudin, B., 2013. Analysis of distance metrics in content-based image retrieval using statistical quantized histogram texture features in the DCT domain. *Journal of King Saud University - Computer and Information Sciences*, 25(2), pp.207–218. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S1319157812000444> [Accessed January 21, 2014].
- Marchiori, A. et al., 2001. CBIR for medical images - an evaluation trial. In *Proceedings IEEE Workshop on Content-Based Access of Image and Video Libraries (CBAIVL 2001)*. IEEE Comput. Soc, pp. 89–93. Available at:

- <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=990861> [Accessed January 20, 2014].
- Medina, J.M., Jaime-Castillo, S. & Jiménez, E., 2012. A DICOM viewer with flexible image retrieval to support diagnosis and treatment of scoliosis. *Expert Systems with Applications*, 39(10), pp.8799–8808. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S0957417412002540> [Accessed January 15, 2014].
- Moreno, R.A. et al., 2012. MedCast: a discussion support system for cooperative work. In W. W. Boonn & B. J. Liu, eds. p. 831912. Available at: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.911663> [Accessed January 22, 2014].
- Morioka, C.A. et al., 2005. Integration of HIS/RIS clinical document with PACS image studies for neuroradiology. In *SPIE International Symposium on Medical Imaging*. San Diego: SPIE.
- Müller, H. et al., 2004. A reference data set for the evaluation of medical image retrieval systems. *Computerized Medical Imaging and Graphics*, 28(6), pp.295–305.
- Müller, H. et al., 2005. Informatics in radiology (infoRAD): benefits of content-based visual data access in radiology. *Radiographics: a review publication of the Radiological Society of North America, Inc*, 25(3), pp.849–58. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/15888631> [Accessed June 24, 2010].
- Müller, H., Gao, X. & Luo, S., 2008. From medical imaging to medical informatics. *Computer methods and programs in biomedicine*, 92(3), pp.225–6. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/18755522> [Accessed January 22, 2014].
- Muramatsu, C. et al., 2008. Investigation of psychophysical similarity measures for selection of similar images in the diagnosis of clustered microcalcifications on mammograms. *Medical physics*, 35(12), pp.5695–702. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/19175126>.
- Névéol, A. et al., 2009. Natural language processing versus content-based image analysis for medical document retrieval. *Journal of the American Society for Information Science and Technology*, 60(1), pp.123–134.
- Nguyen, N.-V. et al., 2012. Cluster-based relevance feedback for CBIR: a combination of query point movement and query expansion. *Journal of Ambient Intelligence and Humanized Computing*, 3(4), pp.281–292. Available at: <http://link.springer.com/10.1007/s12652-012-0141-z> [Accessed January 24, 2014].
- Nishikawa, R.M. et al., 2004. Observers' Ability to Judge the Similarity of Clustered Calcifications on Mammograms. In D. P. Chakraborty & M. P. Eckstein, eds. *Proceedings of SPIE Vol. 5392*. pp. 192–198. Available at: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?articleid=841429> [Accessed January 8, 2014].

- Paredes, R., Deselaers, T. & Vidal, E., 2008. A Probabilistic Model for User Relevance Feedback on Image Retrieval. In A. Popescu-Belis & R. Stiefelhagen, eds. *Machine Learning for Multimodal Interaction, 5th International Workshop*. Utrecht, The Netherlands: Springer, pp. 260–271.
- Park, E.-A. et al., 2009. Efficacy of computer-aided detection system and thin-slab maximum intensity projection technique in the detection of pulmonary nodules in patients with resected metastases. *Investigative radiology*, 44(2), pp.105–13. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/19034026>.
- Park, M., Jin, J.S. & Wilson, L.S., 2002. Fast Content-Based Image Retrieval Using Quasi-Gabor Filter and Reduction of Image Feature Dimension. In *Fifth IEEE Southwest Symposium on Image Analysis and Interpretation (SSIAI.02)*. Santa Fe, New Mexico: IEEE Computer Society, pp. 178–182.
- Penatti, O.A.B. & Torres, R.D.S., 2010. Eva: an evaluation tool for comparing descriptors in content-based image retrieval tasks. In *International Multimedia Conference*. Philadelphia, Pennsylvania, USA: ACM New York, NY, USA, pp. 413–416. Available at: <http://portal.acm.org/citation.cfm?doid=1743384.1743455>.
- Pereira-Jr., R.R. et al., 2007. Usefulness of Texture Analysis for Computerized Classification of Breast Lesions on Mammograms. *Journal of Digital Imaging*, 20(3), pp.248–255.
- Pietrzyk, M.W. et al., 2008. Relations between physical properties of local and global image based elements and the performance of human observers in lung nodule detection. *Progress in biomedical optics and imaging*, 9(34).
- Pirolla, F.R. et al., 2012. Dimensionality reduction to improve content-based image retrieval: A clustering approach. In *2012 IEEE International Conference on Bioinformatics and Biomedicine Workshops*. IEEE, pp. 752–753. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6470232> [Accessed January 24, 2014].
- Ponciano-Silva, M. et al., 2013. Does a CBIR system really impact decisions of physicians in a clinical environment? In *Proceedings of the 26th IEEE International Symposium on Computer-Based Medical Systems*. IEEE, pp. 41–46. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6627762> [Accessed January 22, 2014].
- Ponciano-Silva, M. et al., 2009. Including the perceptual parameter to tune the retrieval ability of pulmonary CBIR systems. In *2009 22nd IEEE CBMS*. IEEE, pp. 1–8.
- Prati, R., Batista, G.H. & Monard, M.C., 2008. Evaluation Classifiers Using ROC Curves. *Latin America Transactions, IEEE*, 6(2), pp.215–222.
- Przelaskowski, A., 2008. Computer-Aided Diagnosis: From Image Understanding to Integrated Assistance. In E. Pietka & J. Kawa, eds. *Information Technologies in Biomedicine*. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 44–54. Available at: <http://www.springerlink.com/content/8t81575x2p7p1763>.

- Rahman, M.M., Antani, S.K. & Thoma, G.R., 2010. A classification-driven similarity matching framework for retrieval of biomedical images. In *International Multimedia Conference*. Philadelphia, Pennsylvania, USA: ACM - New York, NY, USA, pp. 147–154. Available at: <http://portal.acm.org/citation.cfm?doid=1743384.1743413>.
- Rangayyan, R.M., Ayres, F. & Leodesautels, J., 2007. A review of computer-aided diagnosis of breast cancer: Toward the detection of subtle signs☆. *Journal of the Franklin Institute*, 344(3-4), pp.312–348. Available at: <http://dx.doi.org/10.1016/j.jfranklin.2006.09.003>.
- Rebelo, M. de S. et al., 2011. Identification of Structures in Medical Images. In O. F. Erondú, ed. *Medical Imaging*. Available at: <http://www.intechopen.com/books/medical-imaging/identification-of-structures-in-medical-images>.
- Ribeiro, E.A. et al., 2011. Automatic quantitative evaluation of vertebral morphometry in radiographic images. *International Journal of CARS*, 6(Suppl 1), pp.529–533.
- Ribeiro, M.X., 2008. *Suporte a sistemas de auxílio ao diagnóstico e de recuperação de imagens por conteúdo usando mineração de regras de associação*. Universidade de São Paulo.
- Ribeiro, M.X. et al., 2009. Supporting content-based image retrieval and computer-aided diagnosis systems with association rule-based techniques. *Data & Knowledge Engineering*, 68(12), pp.1370–1382. Available at: <http://dx.doi.org/10.1016/j.datak.2009.07.002>.
- Rocchio, J J, 1971. *Relevance Feedback in Information Retrieval*, Englewood Cliffs, New Jersey: Prentice-Hall.
- Rocchio, J. J., 1971. *Relevance Feedback in Information Retrieval. The SMART Retrieval System: Experiments in Automatic Document Processing*, Englewood Cliffs, New Jersey: Prentice-Hall.
- Rorissa, A., Clough, P. & Deselaers, T., 2008. Exploring the relationship between feature and perceptual visual spaces. *Journal of the American Society for Information Science and Technology*, 59(5), pp.770–784.
- Rosa, N.A. et al., 2002. Sistema de Recuperação de Imagens Similares em um Hospital Universitário. In *VIII Congresso Brasileiro de Informática em Saúde- CBIS'2002*. Natal, RN-Brazil.
- Rubin, R.S. et al., 2003. Avaliação de Fraturas Ósseas através da análise de Texturas em Imagens Radiográficas. In *II Workshop Regional em Engenharia Biomédica e I Simpósio Regional de Instrumentação e Imagens Médicas*. São Pedro, SP, p. 46.
- Sahiner, B. et al., 2009. Multi-modality CADx: ROC study of the effect on radiologists' accuracy in characterizing breast masses on mammograms and 3D ultrasound images. *Academic radiology*, 16(7), pp.810–8. Available at: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=2722036&tool=pmcentrez&rendertype=abstract>.

- Samala, R. et al., 2009. A novel approach to nodule feature optimization on thin section thoracic CT. *Academic radiology*, 16(4), pp.418–27. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/19268853>.
- Santos, J.A. dos, Ferreira, C.D. & Torres, R. da S., 2008. A Genetic Programming Approach for Relevance Feedback in Region-Based Image Retrieval Systems. In *XXI Brazilian Symposium on Computer Graphics and Image Processing*. Campo Grande, Brazil: IEEE Computer Society, pp. 155–162.
- Santos, L.F.D., 2012. *Explorando variedade em consultas por similaridade*. Dissertação de Mestrado. Universidade de São Paulo.
- Sedghi, S., Sanderson, M. & Clough, P., 2012. How do health care professionals select medical images they need? *Aslib Proceedings*, 64(4), pp.437–456. Available at: <http://www.emeraldinsight.com/10.1108/00012531211244815> [Accessed January 20, 2014].
- Seshadri, S.B. et al., 2003. Prototype medical image management system (MIMS) at the University of Pennsylvania: software design considerations. 1987. *Journal of digital imaging: the official journal of the Society for Computer Applications in Radiology*, 16(1), pp.96–102; discussion 95. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/12945818> [Accessed June 24, 2010].
- Shyu, C. et al., 1999. ASSERT: A Physician-in-the-loop Content-Based Retrieval System for HRCT Image Databases. Available at: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.40.9268>.
- Smeulders, A.W.M. et al., 2000. Content-Based Image Retrieval at the End of the Early Years. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 22(12), pp.1349–1380.
- Sousa, E.P.M. de, 2006. *Identificação de Correlações usando a Teoria dos Fractais*. Universidade de São Paulo.
- Souza, J.P. de, 2012. *Modelo de qualidade para desenvolvimento e avaliação da viabilidade clínica de sistemas de recuperação de imagens médicas baseada em conteúdo*. Tese de Doutorado. Universidade de São Paulo.
- Souza-Jr, A.S. et al., 2002. Terminologia para a Descrição de Tomografia Computadorizada do Tórax. *Radiologia Brasileira - Educação em Radiologia*, 35(2), pp.125–128.
- Stehling, R.O., Nascimento, M.A. & Falcão, A.X., 2002. A compact and efficient image retrieval approach based on border/interior pixel classification. In *Proceedings of the eleventh international conference on Information and knowledge management - CIKM '02*. New York, New York, USA: ACM Press, p. 102. Available at: <http://portal.acm.org/citation.cfm?doid=584792.584812> [Accessed January 22, 2014].
- Tan, Y. et al., 2006. Content-based image retrieval in picture archiving and communication systems. In *Medical Imaging 2006: PACS and Imaging Informatics*. Proceedings of the SPIE, pp. 282–289.

- Tao, Y. et al., 2007. A preliminary study of content-based mammographic masses retrieval. In *A preliminary study of content-based mammographic masses retrieval*. Proceedings of SPIE, pp. 1Z–1–12.
- Thawait, S.K. et al., 2013. Comparison of four prediction models to discriminate benign from malignant vertebral compression fractures according to MRI feature analysis. *AJR. American journal of roentgenology*, 200(3), pp.493–502. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/23436836> [Accessed January 8, 2014].
- Theodoridis, S. & Koutroumbas, K., 2008. *Pattern Recognition* 4th Editio., New York: Academic Press.
- Torres, R.D.S. & Falcão, A.X., 2006. Content-Based Image Retrieval: Theory and Applications. *Revista de Informática Teórica e Aplicada*, 13(2), pp.161–185.
- Tourassi, G. et al., 2013. Comparative analysis of data collection methods for individualized modeling of radiologists' visual similarity judgments in mammograms. *Academic radiology*, 20(11), pp.1371–80. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/24119349> [Accessed January 7, 2014].
- Town, C., 2013. Content-Based and Similarity-Based Querying for Broad-Usage Medical Image Retrieval. In A. S. Sidhu & S. K. Dhillon, eds. *Advances in Biomedical Infrastructure 2013*. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 63–76. Available at: <http://link.springer.com/10.1007/978-3-642-37137-0> [Accessed January 15, 2014].
- Traina, A.J.M. et al., 2003. Efficient Content-based Image Retrieval through Metric Histograms. *World Wide Web Journal (WWWJ)*, 6(2), pp.157–185.
- Traina, A.J.M. et al., 2009. How to Cope with the Performance Gap in Content-Based Image Retrieval Systems. *International Journal of Healthcare Information Systems and Informatics (IJHISI)*, 4(1), pp.47–67.
- Traina, A.J.M. et al., 2002. The Metric Histogram: A New and Efficient Approach for Content-based Image Retrieval. In X. Zhou & P. Pu, eds. *Sixth IFIP Working Conference on Visual Database Systems*. Brisbane, Australia: Kluwer Academic Publishers, pp. 297–311.
- Traina Jr., C. et al., 2002. How to Improve the Pruning Ability of Dynamic Metric Access Methods. In *International Conference on Information and Knowledge Management (CIKM)*. McLean, VA, USA: ACM Press, pp. 219–226.
- Traina Jr., C. et al., 2000. Slim-Trees: High Performance Metric Trees Minimizing Overlap Between Nodes. In C. Zaniolo et al., eds. *International Conference on Extending Database Technology (EDBT)*. Konstanz, Germany: Springer Verlag, pp. 51–65.
- Traina Jr., C. et al., 2007. The OMNI-Family of All-Purpose Access Methods: A Simple and Effective Way to Make Similarity Search More Efficient. *The International Journal on Very Large Databases*, To appear.

- Tsikrika, T., Müller, H. & Kahn-Jr, C.E., 2012. Log Analysis to Understand Medical Professionals' Image Searching Behaviour. *Studies in health technology and informatics*, 180, pp.1020 – 1024.
- Valente, F., Costa, C. & Silva, A., 2013. Dicoogle, a PACS featuring profiled content based image retrieval. *PloS one*, 8(5), p.e61888. Available at: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3646026&tool=pmcentrez&rendertype=abstract> [Accessed January 21, 2014].
- Vieira, M.R., 2004. *DBM-Tree: Método de Acesso Métrico Sensível à Densidade Local*. Universidade de São Paulo.
- Vimina, E.R. & Jacob, K.P., 2012. Image retrieval using local and global properties of image regions with relevance feedback. In *Proceedings of the International Conference on Advances in Computing, Communications and Informatics - ICACCI '12*. New York, New York, USA: ACM Press, p. 683. Available at: <http://dl.acm.org/citation.cfm?doid=2345396.2345508> [Accessed January 24, 2014].
- Wang, J., Betke, M. & Ko, J.P., 2006. Pulmonary fissure segmentation on CT. *Medical Image Analysis*, 10, pp.530–547.
- Wang, J., Li, F. & Li, Q., 2010. Usefulness of texture features for segmentation of lungs with severe diffuse interstitial lung disease. In N. Karssemeijer & R. M. Summers, eds. *Medical Imaging 2010: Computer-Aided Diagnosis*. San Diego, California, USA: SPIE, p. 76242W–8. Available at: <http://link.aip.org/link/?PSI/7624/76242W/1>.
- Wang, X.-Y. et al., 2014. An image retrieval scheme with relevance feedback using feature reconstruction and SVM reclassification. *Neurocomputing*, 127, pp.214–230. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S0925231213008783> [Accessed January 25, 2014].
- Wang, X.-Y., Zhang, B.-B. & Yang, H.-Y., 2013. Active SVM-based relevance feedback using multiple classifiers ensemble and features reweighting. *Engineering Applications of Artificial Intelligence*, 26(1), pp.368–381. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S0952197612001042> [Accessed January 24, 2014].
- Wangenheim, C.G. von & Wangenheim, A. Von, 2003. *Raciocínio Baseado em Casos*, Curitiba: Editora Manole.
- Welter, P. et al., 2011. Bridging the integration gap between imaging and information systems: a uniform data concept for content-based image retrieval in computer-aided diagnosis. *Journal of the American Medical Informatics Association: JAMIA*, 18(4), pp.506–510. Available at: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3128392&tool=pmcentrez&rendertype=abstract> [Accessed January 24, 2014].
- Welter, P. et al., 2012. Generic integration of content-based image retrieval in computer-aided diagnosis. *Computer methods and programs in biomedicine*, 108(2), pp.589–99.

Available at: <http://www.ncbi.nlm.nih.gov/pubmed/21975083> [Accessed January 22, 2014].

- Welter, P. et al., 2010. Workflow management of content-based image retrieval for CAD support in PACS environments based on IHE. *International journal of computer assisted radiology and surgery*, 5(4), pp.393–400. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/20379792> [Accessed August 26, 2010].
- Van de Wetering, R. & Batenburg, R., 2009. A PACS maturity model: a systematic meta-analytic review on maturation and evolvability of PACS in the hospital enterprise. *International journal of medical informatics*, 78(2), pp.127–40. Available at: <http://www.ncbi.nlm.nih.gov/pubmed/18752988> [Accessed July 27, 2010].
- Willy, P.M. & Kufer, K.-H., 2004. Content-based medical image retrieval (CBMIR): an intelligent retrieval system for handling multiple organs of interest. In *Proceedings. 17th IEEE Symposium on Computer-Based Medical Systems*. IEEE Comput. Soc, pp. 103–108. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1311699> [Accessed June 24, 2010].
- Wu, K. & Yap, K.-H., 2007. Content-based image retrieval using fuzzy perceptual feedback. *Multimedia Tools and Applications*, 32(3), pp.235–251. Available at: <http://link.springer.com/10.1007/s11042-006-0050-2> [Accessed January 8, 2014].
- Xu, S. et al., 2012. Predictive modeling of human perception subjectivity: feasibility study of mammographic lesion similarity. In C. K. Abbey & C. R. Mello-Thoms, eds. *Proc. SPIE*. p. (8318) 0M–9. Available at: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.913639> [Accessed January 7, 2014].
- Xu, X., 2010. Re-weighting relevance feedback image retrieval algorithm based on particle swarm optimization. In *2010 Sixth International Conference on Natural Computation*. IEEE, pp. 3609–3613. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5584092> [Accessed January 24, 2014].
- Xue, Z. et al., 2007. Investigating CBIR techniques for cervicographic images. In *Proceedings of the American Medical Informatics Association*. Proceedings of AMIA.
- Xue, Z. et al., 2011. Spine X-ray image retrieval using partial vertebral boundaries. In *2011 24th International Symposium on Computer-Based Medical Systems (CBMS)*. IEEE, pp. 1–6. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5999147> [Accessed January 15, 2014].
- Yanxi Liu Dellaert, F., 1998. A classification based similarity metric for 3D image retrieval. In *Proceedings. 1998 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (Cat. No.98CB36231)*. IEEE Comput. Soc, pp. 800–805. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=698695> [Accessed June 24, 2010].

- Ye, Z. et al., 2010. Revisiting Rocchio's Relevance Feedback Algorithm for Probabilistic Models. In *Asia Information Retrieval Societies Conference*. pp. 151–161.
- Zhang, D.S. & Lu, G., 2002. An Integrated Approach to Shape Based Image Retrieval. In *Fifth Asian Conference on Computer Vision*. Melbourne, Australia, pp. 652–657.
- Zhang, D.S. & Lu, G., 2001. Content-Based Shape Retrieval Using Different Shape Descriptors: A Comparative Study. In *IEEE Conference on Multimedia and Expo (ICME'01)*. Tokyo, Japan: IEEE Computer Society, pp. 317–320.
- Zhang, H. et al., 2013. Attribute-augmented semantic hierarchy: towards bridging semantic gap and intention gap in image retrieval. In *Proceedings of the 21st ACM international conference on Multimedia - MM '13*. New York, New York, USA: ACM Press, pp. 33–42. Available at: <http://dl.acm.org/citation.cfm?doid=2502081.2502093> [Accessed January 24, 2014].
- Zhou, X.S. et al., 2008. Semantics and CBIR: a medical imaging perspective. In J. Luo et al., eds. *International Conference on Image and Video Retrieval*. Niagara Falls, Canada: ACM, pp. 571–580.