

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito: 19/02/2004

Assinatura : *Ana Paula Japao Traina*

Ampliando o poder de recuperação de imagens por conteúdo utilizando histogramas adaptados: aplicações em imagens médicas

Camilo Yamauchi Campo

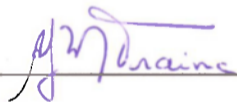
Orientadora: Prof^a. Dr^a. Agma Juci Machado Traina

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação - ICMC-USP como parte dos requisitos para obtenção do título de Mestre em Ciências de Computação e Matemática Computacional.

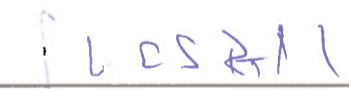
USP - São Carlos
Fevereiro de 2004

A Comissão Julgadora:

Profa. Dra. Agma Juci Machado Traina



Prof. Dr. João do Espírito Santo Batista Neto



Profa. Dra. Roseli de Deus Lopes



Este documento foi preparado utilizando o formatador de textos \LaTeX . Sua bibliografia é gerada automaticamente pelo \BIBTeX , utilizando o estilo Apalike.

© Copyright 2004 - Camilo Yamauchi Campo
Todos os direitos Reservados

Agradecimentos

Primeiramente ao meu Senhor Deus por guiar minha vida em direções certas, nos momentos difíceis. Obrigado Senhor pela sua presença. Aos meus pais que muito me ajudaram, ensinando valores éticos, morais e sociais. Principalmente pela paciência decorrente de minha ausência nos finais de semana em que não pude voltar para o aconchego do lar. À Patrícia que sempre me apoiou, estando ao meu lado nos momentos difíceis de minha vida. Aos meus mestres que passaram seus conhecimentos de forma humilde e atenciosa. À minha orientadora, Profa. Dra. Agma J. M. Traina pela paciência, confiança e incentivo que motivaram meus trabalhos e estudos e ao seu marido, Caetano Traina Jr. pela dedicação, amizade e humildade. Aos membros do GBDI pelo acolhimento, companheirismo e ensinamentos. Em especial à Josiane e a Natália que sempre estiveram dispostas a me atender e tirar quaisquer dúvidas com paciência e simpatia. Aos funcionários do ICMC, setor de pós-graduação, assistência acadêmica, seção de alunos da graduação e funcionárias que, semanalmente, contribuíram com o bom funcionamento da infra-estrutura do laboratório e da universidade. Ao pessoal do futebol que, todas as sextas feiras, compareciam “pontualmente” para a partida. Aos meus companheiros de laboratório, “Beija-Flor” e “Magoó”. À minha turma de Bacharelado em Computação de 1998 e aos meus veteranos de 1997. Nunca os esquecerei. Aos companheiros do conjunto residencial universitário, conhecido como Alojamento, pelo espírito fraterno e ao desapego aos bens materiais. Seus ensinamentos foram de grande valia. Ao pessoal do RUA de São Paulo pela amizade, viagens e festas de longa data. Aos meus amigos e amigas pelos trabalhos, conversas, projetos, discussões, debates, reuniões, comemorações, piadas, brincadeiras e festas que passamos juntos. Aos colegas da pós-graduação e da graduação, pelo companheirismo e unidade em que tenho convivido, em especial à galera da SACIM. Às pessoas que não foram citadas¹ pela falta de espaço, mas que muito me ajudaram no decorrer da vida. Por fim, ao CNPq pela ajuda financeira e confiança depositada neste trabalho.

¹Evitei fazer citações às pessoas para evitar qualquer tipo de injustiça. Amo todas as pessoas com quem convivo e, enumera-las, seria um trabalho infinitamente mais complexo que esta dissertação.

Resumo

Os sistemas de recuperação de imagens baseada em conteúdo (CBIR - *Content-Based Image Retrieval*) vêm sendo bastante estudados e pesquisados atualmente. Isso ocorre especialmente devido às áreas de aplicabilidade, entre as quais tem-se a área médica, onde há uma enorme quantidade de informação armazenada em forma de imagens. Muitas das consultas de interesse dos médicos visam procurar imagens de pacientes que tenham semelhança entre si. Desse modo, estudos de casos, diagnósticos e tratamentos podem ser verificados e comparados baseando-se apenas na imagem e não em descrições textuais sobre elas. Atualmente, os sistemas PACS (*Picture Archiving and Communication Systems*) não são capazes de realizar consultas de imagens por similaridades. O trabalho aqui apresentado implementa um recurso adicional para um PACS com suporte a consultas por similaridade, ampliando o poder de recuperação de imagens através de histogramas. Este recurso permite que o sistema seja capaz de realizar buscas em imagens mesmo com algumas variações de intensidade de brilho, o que é um problema comum já que a aquisição de imagens é realizada por diversos equipamentos e mesmo com diferentes configurações.

Abstract

In the last few years there is a great effort on developing the Content-Based Image Retrieval (CBIR) systems. This is due to their applicability in many fields that deal with images, including particularly the medicine, because the ever increasing volume of data generated by image exams. Many times the physicians try to find images that are similar regarding some specific aspect. Therefore, case studies, diagnosis and treatment can be compared and checked based only on the pictorial information of the images. The traditional Picture Archiving and Communication Systems (PACS) do not support similarity queries. Thus, this work presents a new technique to improve the execution of similarity queries based on the brightness histogram of images. This technique allows the system to compare, by histograms, images with brightness variations, bypassing a claimed drawback of histograms to characterize images. This brightness variation is a common problem in acquiring images, as different devices and settings can be used to generate them, producing different brightness distribution over the whole image.

Lista de Abreviaturas

ACR	<i>American College of Radiology</i>
BIC	<i>Border/Interior Pixel Classification</i>
BLOB	<i>Binary Large Object</i>
CBIR	<i>Content-based Image Retrieval</i>
CCD	<i>Charge-coupled devices</i>
CCIFM	Centro de Ciências das Imagens e Física Médica
CR	<i>Computer Radiography</i>
CT	<i>Computer Tomography</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
DR	<i>Direct Radiography</i>
FMRP	Faculdade de Medicina de Ribeirão Preto
GBDI	Grupo de Bases de Dados e de Imagens
HC	Hospital das Clínicas
HIS	<i>Hospital Information System</i>
HM	Histograma Métrico
HSI	<i>Hue, Saturation and Intensity</i>
ICMC	Instituto de Ciências Matemáticas e de Computação
JPEG	<i>Joint Photographic Experts Group</i>
MBB	<i>Minimum Boundary Box</i>
MAE	Método de Acesso Espacial

MAM	Método de Acesso Métrico
MST	<i>Minimal Spanning Tree</i>
MRI	<i>Medical Resonance Image</i>
NN	<i>Nearest Neighbor</i>
PACS	<i>Picture Archiving and Communication System</i>
RAID	<i>Redundant Array of Inexpensive Disks</i>
RGB	<i>Red, Green and Blue</i>
RGHC	Registro Geral do Hospital das Clínicas
RIS	<i>Radiology Information System</i>
RM	Ressonância Magnética
RMN	Ressonância Magnética Nuclear
RSNA	<i>Radiological Society of North America</i>
SAM	Sistema de Arquivo Médico
SGBD	Sistema de Gerenciamento de Base de Dados
SRIS	Sistema de Recuperação de Imagens por Similaridade
USP	Universidade de São Paulo
WORM	<i>Write-Only Read-Many</i>

Sumário

1	Introdução	1
1.1	Considerações Iniciais	1
1.2	Motivação	3
1.3	Objetivos	4
1.4	Apresentação do Trabalho	5
2	Os Sistemas PACS	6
2.1	Introdução	6
2.2	Tecnologia de Aquisição de Imagens	9
2.3	Aquisição de Imagens e Interfaces PACS	11
2.4	Tecnologia de Armazenamento no PACS	12
2.5	Exibição de Imagens	14
2.6	Rede PACS	15
2.7	Serviço de Radiologia Digital (<i>filmless</i>) em Hospital Universitário	16
2.8	Sistema de Informação em Radiologia (RIS) do Hospital das Clínicas - HCFMRP	17
2.9	Conclusão	20
3	Extração de Características de Imagens	22
3.1	Considerações Iniciais	22
3.2	Definindo uma Imagem	23
3.3	Atributos das Imagens	24
3.3.1	Cor	25
3.3.2	Textura	26

3.3.3	Forma	27
3.3.4	Resumo das características de baixo nível das imagens	29
3.4	Importância da Extração de Características	29
3.5	Algumas Abordagens sobre os sistemas CBIR	33
3.5.1	O Histograma Métrico	33
3.5.2	Classificação de <i>Pixels</i> de Borda e Interior - A Técnica BIC	37
3.6	Considerações Finais	39
4	Consultas por Similaridade e Estruturas Métricas	40
4.1	Considerações Iniciais	40
4.2	Tipos de Buscas por Similaridade	41
4.3	Métodos de Acesso Métricos	42
4.4	Estruturas Estáticas e Dinâmicas	43
4.5	A Slim-tree	44
4.6	Inserção de Objetos na Slim-tree	46
4.7	Tratamento de Sobreposição	47
4.7.1	Reorganização dos Nós da Árvore - Algoritmo <i>Slim-down</i>	49
4.7.2	Visualização dos Dados Armazenados na Slim-tree	49
4.8	Considerações Finais	49
5	Trabalho Desenvolvido	51
5.1	Considerações Iniciais	51
5.2	Protótipo de um SRIS baseado no DicomViewer	52
5.2.1	Formato de arquivos	53
5.2.2	Filtros e Bordas	54
5.2.3	Visualização e opções	55
5.2.4	LocalcbPACS	56
5.2.5	BIC	57
5.3	O Histograma Métrico Adaptado	58
5.4	O Sistema de Recuperação de Imagens do Hospital das Clínicas de Ribeirão Preto	63
5.4.1	Arquitetura do SRIS-IIC	65
5.5	Resultados	72
5.6	Considerações Finais	75

6 Conclusão e Trabalho Futuros	79
6.1 Considerações Finais	79
6.2 Trabalhos Futuros	80
Referências Bibliográficas	87
A Demais Resultados	88
A.1 Caso 2	88
A.2 Caso 3	90
A.3 Caso 4	90

Lista de Figuras

2.1	Infraestrutura de um PACS em ambiente hospitalar.	7
2.2	Esquema das funções de um PACS [Rosa, 2002].	8
2.3	Armazenamento de um PACS combinando arquivamento <i>online</i> , <i>nearline</i> e <i>offline</i> através de um gerenciador de base de dados.	14
2.4	Tela principal do Sistema RIS do HCFMRP.	17
2.5	Esquema do processo global do RIS ilustrando o fluxo de um exame radiológico [Rosa, 2002].	18
3.1	Uma imagem e seu histograma normalizado.	24
3.2	Exemplos de imagens diferentes (<i>a</i> , <i>b</i> , <i>c</i> e <i>d</i>) que possuem o mesmo histograma de cores (<i>e</i>).	25
3.3	Exemplo de texturas.	26
3.4	Exemplo de uma imagem original em tons de cinza (<i>a</i>) e sua forma segmentada mostrando 4 objetos identificados (<i>b</i>) [Petrakis and Faloutsos, 1997].	28
3.5	Etapas de reconhecimento de padrões de imagens.	31
3.6	Histograma normalizado com os pontos $\langle b_k, h_k \rangle$ que definem os <i>buckets</i> e seu Histograma Métrico correspondente.	34
3.7	Obtendo o Histograma Métrico sobre o normalizado. Os pontos de controle são apresentados pelos elementos circulares e o Histograma Métrico pela curva que está ao redor do histograma normalizado.	35

3.8	Imagem original (a), imagem mais semelhante (b) e imagem menos semelhante (c). Os histogramas apresentam a densidade de <i>pixels</i> para 256 níveis de cinza das imagens.	36
3.9	Distância entre dois Histogramas Métricos calculando a soma da diferença entre áreas.	37
3.10	Análise de imagens pela abordagem BIC. Imagem original (esquerda). Classificação binária entre borda (preto) e interior (branco) (centro). (c) <i>Pixels</i> da borda com suas cores originais e os <i>pixels</i> do interior em branco (direita). . .	38
4.1	A consulta por abrangência (esquerda) seleciona todas as estrelas distantes de um raio r enquanto que a consulta aos vizinhos mais próximos (direita) seleciona as 5 estrelas mais próximas do elemento de consulta.	42
4.2	Estrutura lógica dos nós a) índice (indexNode) e b) folha (leafNode) da Slim-tree [Traina et al., 2000].	45
4.3	Representação da Slim-tree armazenando 17 objetos.	45
4.4	Mecanismos de quebras de nós do algoritmo MST.	47
5.1	Interface padrão do DicomViewer, software que serviu de base para a implementação do protótipo.	53
5.2	Exemplos de utilização dos filtros do DicomViewer. a) imagem original, b) após aplicação do filtro da mediana com fator 2, c) após processamento de auto-levels e d) com adição de 100 unidades de brilho.	55
5.3	Consulta por similaridade no protótipo adicionado ao DicomViewer.	57
5.4	Imagem de exame de tomografia axial de cabeça humana. (a) imagem original, (b) imagem com o brilho alterado e (c) imagem com o contraste alterado. . .	59
5.5	Ilustração de como é realizado a invariância ao brilho no Histograma Métrico.	60
5.6	Histograma com seu contraste alterado através do <i>stretching</i> simples e seu Histograma Métrico correspondente. A utilização do limite V_L elimina os <i>bins</i> irrelevantes, recuperando sua curva original (à direita).	60
5.7	Ilustração do funcionamento da <i>Warp Distance</i> onde ocorre a “distorção” de área permitindo um melhor cálculo de similaridade entre curvas.	61
5.8	Consulta <i>32-Nearest Neighbors</i> utilizando a abordagem BIC.	62
5.9	Consulta <i>32-Nearest Neighbors</i> utilizando a abordagem do Histograma Métrico.	62
5.10	Integração SRIS-HC com RIS, HIS e mini-PACS do HCFMRP/USP.	63
5.11	Processo global do Sistema de Recuperação de Imagens Similares - SRIS-HC.	65

5.12	Arquitetura do SRIS-HC.	66
5.13	Interface em que as imagens GBDI são inseridas para validação.	67
5.14	Tela de consulta ao laudos de um paciente e suas respectivas informações. . .	70
5.15	Tela das imagens em miniatura (<i>thumbnails</i>) do exame e a primeira imagem em tamanho natural.	71
5.16	Tela da apresentação dos <i>logs</i> do banco de imagens.	72
5.17	Tela de conexão do usuário com a base de dados e acesso ao SRIS-HC. . . .	72
5.18	Imagem original de crânio (esquerda) e a mesma com o recorde do MBB (<i>Minimum Boundary Box</i>).	73
5.19	Imagem de referência para o primeiro caso.	74
5.20	Resultado da consulta aos 40 vizinhos mais próximos utilizando o histograma normalizado.	75
5.21	Consulta por abrangência com raio de 0.3 utilizando o histograma normalizado. 76	
5.22	Consulta aos vizinhos mais próximos através do Histograma Métrico adaptado. 76	
5.23	Consulta por abrangência com raio de 0.3 utilizando o Histograma Métrico adaptado.	77
A.1	Imagem de referência do Caso 2.	88
A.2	Consulta aos 40 vizinhos mais próximos utilizando o histograma normalizado. 89	
A.3	Consulta por abrangência ($r = 0.3$) utilizando o histograma normalizado. . .	89
A.4	Consulta aos 40 vizinhos mais próximos utilizando o Histograma Métrico adaptado.	90
A.5	Consulta por abrangência ($r = 0.3$) utilizando o Histograma Métrico adaptado. 91	
A.6	Imagem de referência do Caso 3.	91
A.7	Consulta aos 40 vizinhos mais próximos utilizando o histograma normalizado. 92	
A.8	Consulta por abrangência ($r = 0.3$) utilizando o histograma normalizado. . .	92
A.9	Consulta aos 40 vizinhos mais próximos utilizando o Histograma Métrico adaptado.	93
A.10	Consulta por abrangência ($r = 0.3$) utilizando o Histograma Métrico adaptado. 93	
A.11	Imagem de referência do Caso 4.	94
A.12	Consulta aos 40 vizinhos mais próximos utilizando o histograma normalizado. 95	
A.13	Consulta por abrangência ($r = 0.3$) utilizando o histograma normalizado. . .	95
A.14	Consulta aos 40 vizinhos mais próximos utilizando o Histograma Métrico adaptado.	96
A.15	Consulta por abrangência ($r = 0.3$) utilizando o Histograma Métrico adaptado. 96	

Lista de Tabelas

3.1	Atributos de qualidade das características de baixo nível da imagem [Vailaya, 2000].	30
3.2	Taxonomia sobre espaços de características extraídas de imagens[Brown, 1992].	32
5.1	Tabela de comparação entre o DicomViewer e as incorporações realizadas. . .	54
5.2	Configuração do computador utilizado para os experimentos.	74
5.3	Resumo dos resultados obtidos nos experimentos.	78

Introdução

1.1 Considerações Iniciais

Os Sistemas de Informações Hospitalares (HIS) armazenam informações relativas aos pacientes destacando-se, entre elas, seu estado de saúde, os exames realizados e os procedimentos médicos adotados. Atualmente, a maioria desses sistemas organiza dados textuais e numéricos mas, em alguns casos, já é possível a associação das informações textuais com informações gráficas, provenientes de exames como raio-X, tomografia (CT¹ ou RM²) e ultra-som. Recentemente, com a introdução dos sistemas PACS (*Picture Archiving and Communication System*) [Cao and Huang, 2000] [Siegel, 1999] [Furuie et al., 1999] [Marsh, 1997], cresceu o interesse por integrar num só sistema todas as informações dos pacientes (textos, imagens, gráficos e dados temporais). Além disso, o custo operacional dos exames de imagens diminui quando se utiliza tecnologia de radiologia sem filme (*filmless*), o que permite direcionar investimentos maiores para a área de diagnóstico [Siegel, 1999].

Os sistemas PACS devem permitir a transmissão rápida e o armazenamento organizado para as imagens digitais, tanto em termos de disponibilidade do exame em curto prazo como

¹Tomografia Computadorizada.

²Ressonância Magnética.

também no aspecto de multivisualização. Os cirurgiões devem ser capazes de tomar decisões diagnósticas logo após um exame, bem como acessá-las simultaneamente para discuti-las e analisá-las em salas de ensino ou mesmo durante consultas [Siegel and Kolodner, 1999] [Furuie et al., 1999].

Infelizmente, os poucos sistemas PACS comerciais oferecidos atualmente são extremamente caros e não contemplam todas as necessidades do centro médico [Sung et al., 2000]. Desse modo, o estado da arte na área resume-se ao desenvolvimento de soluções locais, muitas vezes restritas. Alguns centros médicos integrados a unidades de pesquisa optam, via de regra, por adquirir apenas alguns módulos do sistema, desenvolvendo e adaptando outros módulos e criando soluções próprias conforme sua necessidade. Assim, o custo é diminuído e podem-se contemplar necessidades e características próprias de cada ambiente.

Como os sistemas PACS organizam as imagens provenientes de exames efetuados sobre os pacientes, seria muito interessante que, através desses sistemas, fosse possível realizar consultas e recuperar tais imagens baseando-se apenas no seu conteúdo. Por exemplo, pode ser necessário recuperar todas as imagens obtidas em exames de tomografias computadorizadas do coração, similares a uma imagem dada. Nesse caso, o cruzamento das informações é independente das chaves de busca tradicionais, baseadas em dados numéricos e textuais, as quais associam exames e pacientes em um HSI tradicional. A facilidade de recuperação de dados baseada em seu conteúdo é um dos recursos atualmente mais almejados para incorporação aos sistemas PACS [Korn et al., 1996] [Lima et al., 1998]. Através dessa facilidade, podem ser encontrados registros de pacientes cujas imagens associadas apresentam aspectos de similaridade (utilizando padrões gráficos), além de se obterem correlações utilizando sintomas previamente registrados e tratamentos efetuados [Marsh, 1997]. Assim, um sistema PACS com tal facilidade torna-se, potencialmente, uma ferramenta bastante eficaz no auxílio ao diagnóstico médico.

Um sistema PACS pode então responder à consultas por similaridade, isto é, a questões do tipo: *Quais são as 10 imagens mais semelhantes (próximas) de uma dada imagem* ou *Quais são as imagens que diferem em até 5 unidades de uma imagem padrão*. Vale notar que tanto as imagens quanto a função distância (dissimilaridade) definida são, usualmente, dependentes do domínio de dados e do que é considerado “semelhante”.

A similaridade entre imagens pode ser medida de várias formas. Características como formato, cor e textura podem ser extraídas de imagens em uma base de dados e podem ser utilizadas em cálculos de distância ou dissimilaridade [Aslandogan and Yu, 1999].

1.2 Motivação

Ao efetuar uma consulta por similaridade em um banco de imagens, o sistema retorna o conjunto de imagens que responde à solicitação efetuada. A consulta é realizada através de uma ou mais estruturas de índices que dão suporte a busca por imagens semelhantes, considerando a distância entre as características extraídas das imagens. Dessa forma, o conjunto de características extraídas das imagens e a função de dissimilaridade (distância) utilizada têm papel preponderante nessa operação de consulta. “Quais são as características extraídas das imagens que melhor contribuem para a comparação e separação entre as imagens mais precisas?” Os especialistas em visão computacional afirmam que, na realidade, a ciência não sabe dizer como o cérebro humano reconhece as imagens e os objetos que as compõem [Jain and Dubes, 1988]. Porém, existe um consenso de que as principais características são baseadas em atributos de cor, forma e textura. Assim, algumas dessas características podem ser obtidas através de histograma para cores [Aslandogan and Yu, 1999], resultados de transformações tais como momentos (*singular value decomposition* e *Karhunen-Loève*) [Faloutsos, 1996] para formas, além de coeficientes de transformadas *wavelets* (principalmente Gabor)[Albuz et al., 2001] para texturas, entre outras técnicas.

Devido à complexidade de algumas técnicas de extração de características, é mais interessante aplicá-las sobre um conjunto de imagens menor ou que tenha sido refinado por um método menos custoso em termos computacionais. Nesse sentido, as técnicas baseadas em cores e, no caso das imagens médicas, em níveis de brilho ou intensidade, devem ser as primeiras utilizadas, pois requerem baixo custo computacional. Isto ocorre pois as informações relativas a cor são as primeiras a serem lidas em um arquivo de imagem.

Os histogramas de intensidades, que indicam o número de *pixels* da imagem para cada nível de intensidade, são simples de implementar, baratos em termos computacionais e muito utilizados em sistemas CBIR (*Content-Based Image Retrieval*). Como os histogramas apresentam a distribuição global dos níveis de cinza da imagem, eles são também altamente suscetíveis a variações de brilho.

Algumas variações com o uso de histogramas são propostas na literatura. Histogramas que armazenam informações espaciais das cores são apresentados em [Yamamoto et al., 1999], [Chua et al., 1997] e [Rao et al., 1999]. A grande maioria de publicações no tratamento de histogramas para recuperação de imagens por conteúdo traz abordagens nas quais são privilegiados fatores como desempenho e precisão. Nestas abor-

dagens, as técnicas não se detiveram na redução do número de *bins*³ de uma imagem sem perda significativa de informação. Em [Bueno, 2002] [Traina et al., 2002a] foram propostos os Histogramas Métricos (HM) que são invariantes às transformações geométricas (escala, rotação e translação) efetuadas nas imagens. Os HMs são definidos através de uma função de aproximação linear por partes sobre o histograma normalizado da imagem, sendo que tais funções podem ser ajustadas e comparadas. O presente projeto explora as propriedades de invariância dos HMs e apresenta os resultados que permitem uma melhor discriminação das imagens recuperadas através de seu conteúdo.

O Histograma Métrico é uma forma de reduzir a dimensionalidade do vetor de características, porém atua sobre cada vetor de característica da imagem (histograma convencional) de forma independente do conjunto completo, o que permite manter as particularidades de cada imagem. Tal fato não foi explorado por outras técnicas de redução de dimensionalidade de histogramas descritas na literatura da área [Brunelli and Mich, 2001]. Assim, o presente trabalho compara o grau de eficiência dos HMs com outros métodos de redução de dimensionalidade e demonstra que, com tais características invariantes, os HMs possibilitam um alto grau de recuperação de imagens por conteúdo no âmbito das imagens médicas.

1.3 Objetivos

O objetivo deste projeto é estudar e implementar métodos de extração de características baseadas em níveis de intensidade que permitam a comparação entre imagens médicas, sendo um primeiro passo para diminuir o conjunto de resposta para busca de imagens similares. Este passo, permitirá que métodos mais sofisticados, como os baseados em forma, possam ser aplicados *a posteriori* sobre um volume menor de dados, propiciando uma resposta mais rápida à consulta.

O resultado do extrator de características aplicado a uma imagem é um vetor de características, o qual é utilizado para comparar as imagens através de funções de distância. A técnica utilizada é baseada no Histograma Métrico (HM) que são invariantes às três transformações geométricas. Neste trabalho, eles foram expandidos para o tratamento de variações a brilho, tornando-os mais eficientes.

As técnicas desenvolvidas foram validadas no sistema cb-PACS em construção no ICMC-USP e CCIFM-FMRP-USP.

³A definição de *bin* pode ser entendida como a quantidade estatística de uma determinada cor em uma imagem, assim uma imagem com 256 cores possuirá um histograma com 256 *bins*.

1.4 Apresentação do Trabalho

Este trabalho está dividido em 6 capítulos e um apêndice. O primeiro capítulo apresentou algumas considerações iniciais, o contexto no qual se insere este trabalho, a motivação para seu desenvolvimento e seus objetivos finais.

No Capítulo 2 é apresentada a estrutura dos sistemas PACS e suas principais características, além de introduzir o sistema em desenvolvimento no Hospital das Clínicas de Ribeirão Preto.

No Capítulo 3 é apresentada uma visão sobre os extratores de características de imagens, mostrando as principais características das imagens utilizadas em sistemas de recuperação por conteúdo. Dois exemplos de extratores de características são abordados e analisados. As consultas por similaridade e estruturas métricas são descritas no Capítulo 4

O trabalho desenvolvido, os resultados obtidos e a modificação realizada no Histograma Métrico são tratados no Capítulo 5.

Por fim, no Capítulo 6 é apresentada a conclusão e os trabalhos futuros e em seguida, a bibliografia. Um apêndice foi também adicionado para a apresentação dos demais resultados que não foram detalhados no Capítulo 5.

Os Sistemas PACS

2.1 Introdução

Desde o surgimento do Raio-X, descoberto por Wilhelm Conrad Röntgen em 8 de novembro de 1895, a utilização de imagens para diagnóstico de doenças faz parte do meio médico. Com o avanço tecnológico, os equipamentos foram incorporando sistemas mais complexos como a tomografia computadorizada e a ressonância magnética.

Com o advento dos sistemas computacionais, o tratamento de informações vem avançando diariamente. Os sistemas computacionais fazem parte, mais do que em qualquer época, da vida cotidiana. Os computadores são extremamente necessários, principalmente em ambientes em que a quantidade de informações é grande. Exemplos típicos disso são escolas, bancos, empresas e hospitais. Este último possui uma peculiaridade dos demais. Além de necessitar gerenciar informações textuais, há também a necessidade de manipular imagens de exames.

Os chamados Sistemas de Comunicação e Armazenamento de Imagens - PACS, referem-se a sistemas computacionais que são usados para capturar, armazenar, distribuir e exibir imagens médicas. São sistemas de arquivamento e comunicação voltados para o diagnóstico por imagem, que permitem o pronto acesso, em qualquer setor do hospital ou clínica, de imagens médicas em formato digital [Siegel, 1999].

O termo PACS tem sido usado para denotar sistemas nos departamentos de radiologia que lidam com imagens radiológicas, embora alguns PACS tenham ido além desses limites, contendo imagens de outras fontes, tais como patologia e endoscopia. O PACS tem se tornado rapidamente a opção tecnológica preferida para as tarefas de transmissão, armazenamento, recuperação, visualização e interpretação de grandes volumes de dados. Porém, a implementação de um PACS implica em um trabalho de reengenharia do serviço de radiologia, devido às modificações inseridas na seqüência de eventos necessários desde a aquisição da imagem até sua exibição e interpretação [Marques et al., 2000].

Um PACS consiste de pelo menos uma ou múltiplas modalidades (dispositivos de aquisição), uma rede de comunicação, um dispositivo de armazenamento intermediário e/ou de longo período, e uma estação de trabalho para visualização e/ou pós-processamento, conforme esquematizado na Figura 2.1. Um PACS que atende à uma modalidade de exame com imagens, um arquivo e uma estação de trabalho é chamado de mini-PACS ou micro-PACS [Rosa, 2002].

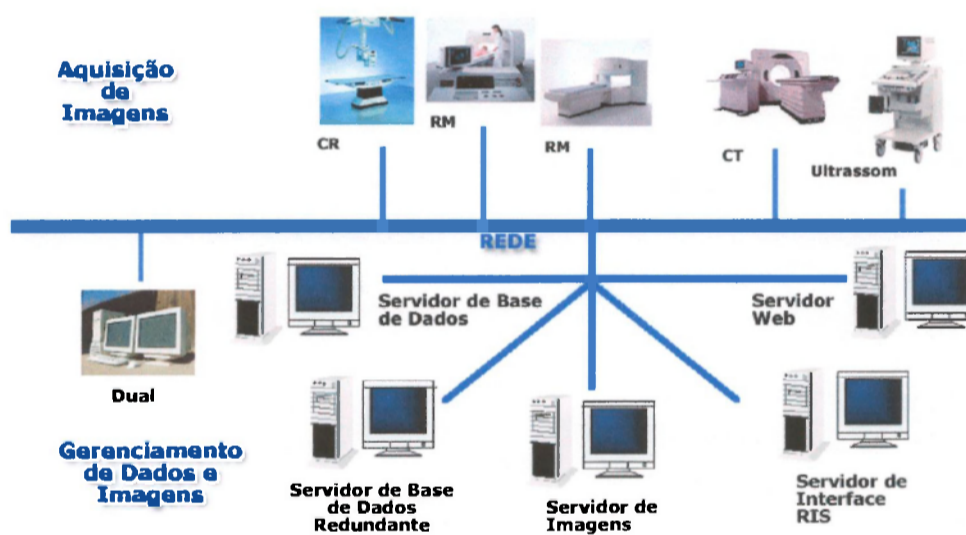


Figura 2.1: Infraestrutura de um PACS em ambiente hospitalar.

Um sistema PACS deve executar as seguintes funções utilizando tecnologia digital [G. Günther, 1999], conforme o esquema elaborado para ilustrar essas funções na Figura 2.2:

- aquisição de imagem
- comunicação de imagens (transferência)
- armazenamento de imagens

- exibição de imagens
- processamento de imagens

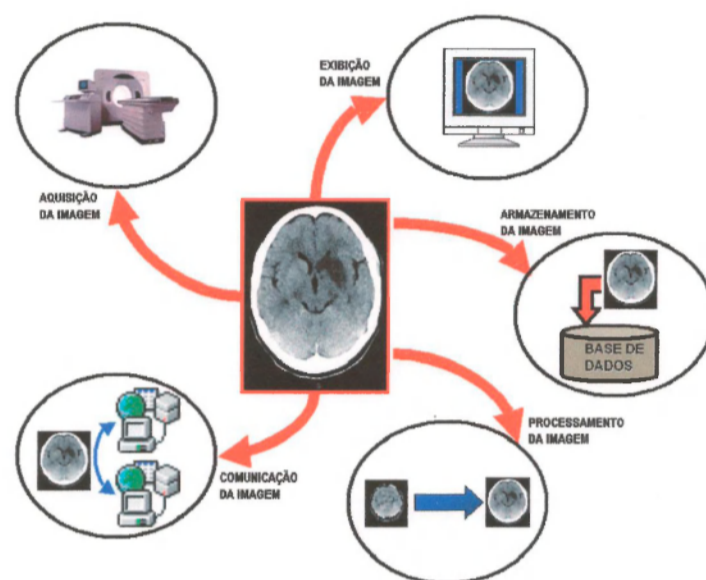


Figura 2.2: Esquema das funções de um PACS [Rosa, 2002].

A tecnologia PACS pode ser utilizada para obter operações sem filme (*filmless*). Radiologia *filmless* se refere a um hospital com um ambiente de rede amplo e integrado, no qual o filme foi completamente, ou em grande parte, substituído por sistemas eletrônicos que adquirem, arquivam, disponibilizam e exibem as imagens [Siegel, 1999][Marques et al., 2000]. O PACS em conjunto com os Sistemas de Informação em Radiologia (RIS) e de Informação Hospitalar (HIS) formam a base para um serviço de radiologia *filmless* [Siegel and Kolodner, 1999] [Marques et al., 2000].

A implantação de um serviço de radiologia sem filme deverá trazer melhorias no que se refere à acessibilidade e integração de informações, pela vinculação de imagens ao registro médico eletrônico do paciente, e no que se refere à aplicação de novas técnicas e desenvolvimentos na aquisição, exibição e processamento de imagens. Segundo a literatura especializada, a maioria dos serviços médicos fará a transição para a radiologia *filmless* durante os próximos dez ou vinte anos [Siegel and Kolodner, 1999] [Marques et al., 2000].

Um alto nível de integração do PACS na operação dos dados é necessário para garantir sua ótima funcionalidade, o que requer uma quantidade tremenda de planejamento e implementação com analistas de sistemas, engenheiros e a administração e também com os outros

departamentos clínicos. Isso é muito mais complexo de se obter do que qualquer outro processo de aquisição para o departamento de radiologia e o hospital [Siegel and Kolodner, 1999].

Um PACS é caracterizado por quatro subsistemas: **aquisição, exibição, disponibilização e armazenamento de imagens** [Marques and et. al, 2004], que serão descritos a seguir.

2.2 Tecnologia de Aquisição de Imagens

Embora as modalidades mais recentes, tais como imagens de ressonância magnética (MRI), tomografia computadorizada (CT), ultra-som, angiografia digital, fluoroscopia digital e medicina nuclear, obtenham imagens em formato digital, aproximadamente 70% da carga de trabalho do departamento de radiologia continuam sendo na área de radiografia convencional (filmes/chapas) [Siegel and Reiner, 1999]. Radiografia geral, com seu alto volume de detalhes na imagem, representa um desafio especial para PACS, desafio esse encontrado com a introdução de novas modalidades, tais como radiografia computadorizada, radiografia direta e digitalização de filmes [Siegel and Kolodner, 1999].

A maioria dos equipamentos para as modalidades digitais, tais como CT, MRI, ultra-som, medicina nuclear, CR, radiografia direta (DR), angiografia e fluoroscopia digital, é atualmente adquirida com interface padrão que utiliza um protocolo de comunicação e formato de imagem conhecido como DICOM (*Digital Imaging and Communications in Medicine*). O formato DICOM é o padrão para comunicação de imagens médicas e informações associadas, atualmente utilizado por diversas modalidades de equipamentos de imagens médicas [Caritá, 2002]. Esse protocolo preserva a fidelidade original completa (resolução espacial e contraste) gerado pela modalidade durante a transferência para o PACS. Na ausência de uma interface DICOM, as imagens podem ser capturadas para transmissão para o PACS usando placas de captura de vídeo, que podem digitalizar a saída de vídeo de um monitor ou câmera. Desafortunadamente existe uma boa quantidade de variação na qualidade das unidades de captura de vídeo e mesmo os melhores podem introduzir artefatos que degradam a qualidade da imagem. Essas unidades estão limitadas à captura de somente 8 bits (256 níveis de cinza), o que é insuficiente para os 12 bits (4096 níveis de cinza) de modalidades tais como CT e MRI [Siegel, 1999].

Um ambiente sem filme requer um nível muito alto de resolução espacial e contraste, resultando em grandes arquivos de imagens (de 6 a 16 Megabytes). Em um ambiente desses, existem somente três métodos atualmente disponíveis para aquisição de radiografias em ge-

ral: Radiografia Computadorizada (CR), Radiografia Direta (DR) e digitalização de filmes [Siegel and Kolodner, 1999].

Radiografia Computadorizada (CR), também conhecida como *Storage Phosphor Radiography* (SP), é atualmente a única solução comercial amplamente disponível para aquisição digital de radiografias convencionais. Nesses sistemas de radiografias computadorizadas, as imagens digitais são diretamente produzidas em uma placa de imagem à base de fósforo (*imaging plate*) podendo, na seqüência, serem visualizadas em monitores ou convertidas para imagem analógica em filme através de um processador laser. A maior vantagem da CR é sua ampla faixa dinâmica e seu uso de pós-processamento de imagens por computador, que resulta em potencial no decréscimo das taxas de repetição de imagens, e melhoria da qualidade do diagnóstico das radiografias [Siegel and Kolodner, 1999]. Os sistemas CR são compatíveis com a maioria dos sistemas de raios-X fixos e portáteis, possuindo latitude de exposição bastante larga, o que resulta em imagens com densidade adequada em uma faixa ampla de níveis de exposição, eliminando os problemas de sobre e sub-exposição das imagens [Marques and et. al, 2004]. Porém existem algumas desvantagens, tais como o alto custo de implantação e o decréscimo na resolução espacial, que é menor do que a do filme, mas é suficiente para o diagnóstico.

Em Radiografia Direta (DR), um conjunto de detectores é utilizado para capturar a imagem radiográfica diretamente, eliminando a necessidade do processar ou ler o detector (filme em um sistema convencional, placa de fósforo em um sistema CR) em outro local. Com um sistema DR totalmente integrado com o sistema de informação do hospital, um técnico pode obter uma série de imagens, revisá-las imediatamente e enviá-las para um PACS. Um sistema sem filme tem a capacidade de aumentar a produtividade. A tecnologia DR também tem a capacidade de aumentar a resolução espacial em comparação com sistemas CR atualmente implementados e diminuir os artefatos associados com os danos físicos que podem ocorrer com o tempo com as placas de fósforo armazenadas. Sua maior desvantagem é o alto custo, a alta vulnerabilidade relativa aos danos dos sistemas de detectores, e a carência de portabilidade [Siegel and Kolodner, 1999].

Na ausência de um dispositivo de aquisição digital, o filme pode ser digitalizado usando um dispositivo digitalizador de filmes (semelhante a uma máquina de fax), que varre o filme e então envia a imagem eletrônica resultante para um dispositivo de armazenamento ou PACS. Os filmes convencionais, teoricamente podem ser digitalizados em um alto nível de resolução espacial e contraste usando um digitalizador de filme de alta qualidade. Existem muitos tipos de digitalizadores de filmes, incluindo sistemas com CCD (*charge-coupled devices*) e varredura

por feixe de laser. Os digitalizadores de filmes podem ser introduzidos sem grandes alterações na rotina do serviço, possibilitando uma transição suave para um sistema baseado em imagem digital [Siegel and Kolodner, 1999] [Marques and et. al, 2004]. Porém na prática, o processo de digitalização pode introduzir artefatos e degradar a qualidade da imagem e, além disso, a qualidade da imagem é limitada à qualidade do filme original [Siegel and Kolodner, 1999]. O processo de digitalização consome tempo devido à necessidade de identificar cada paciente, o estudo executado, data e hora do exame e fornecer essas informações à base de dados do PACS [Siegel and Kolodner, 1999]. A percepção dos radiologistas é que a qualidade da imagem é significativamente limitada para os filmes digitalizados, reduzindo a segurança do diagnóstico. Essas limitações têm resultado na adoção de radiografias computadorizadas preferencialmente à digitalização de filmes [Siegel and Kolodner, 1999].

2.3 Aquisição de Imagens e Interfaces PACS

Ao se planejar um departamento de radiologia sem filme, é importante especificar em detalhes que todas as modalidades terão interfaces digitais com o PACS. Essas interfaces deveriam utilizar o padrão DICOM para comunicação com o PACS, pois o DICOM tem-se firmado como o padrão para imagens médicas. Adicionalmente, os dispositivos de aquisição de imagens deveriam ser adquiridos com a habilidade de permitir a comunicação direta com o sistema de informação hospitalar (HIS) e com o sistema de informação em radiologia (RIS) para facilitar a entrada eletrônica de informações do paciente e de estudos do paciente [Siegel and Kolodner, 1999].

Os dispositivos de aquisição de imagens devem ser capazes de enviar imagens ao PACS rapidamente, para minimizar a espera de tempo dos radiologistas e dos médicos, o que requer, por exemplo, que uma imagem de CR seja transmitida em menos que 36 segundos e 60 imagens de CT em menos que 2 minutos [Siegel and Kolodner, 1999].

Uma das mais importantes lições das recentes implementações de PACS têm sido a importância crítica das interfaces funcionando fácil e confiavelmente. Essas interfaces podem ser vistas como uma estrada de comunicação que permite as modalidades, o PACS e os sistemas de informação hospitalar e em radiologia (HIS/RIS) se comunicarem entre si [Siegel and Kolodner, 1999].

Três tipos de interfaces são necessários para o sucesso da operação de um PACS de larga escala:

- interface das modalidades com o PACS, que permite transferir imagens médicas e

informações de pacientes e estudos de pacientes, dos dispositivos de aquisição (tais como *CT scanner*) para o PACS e transferir potencialmente as imagens do PACS para as modalidades [Siegel and Kolodner, 1999].

- interface dos sistemas HIS/RIS com o PACS, permitindo transferir informações dos pacientes tais como nome, identificação e tipo de estudos para o PACS e do PACS para os sistemas.
- interface do HIS/RIS com as modalidades, permitindo comunicação direta entre um dispositivo de imagens médicas e os sistemas HIS/RIS [Siegel and Kolodner, 1999].

2.4 Tecnologia de Armazenamento no PACS

Uma vez que as imagens são obtidas, elas devem ser armazenadas para pesquisa posterior dos médicos e dos radiologistas. O armazenamento das imagens tem se dividido, tradicionalmente, em curto período (*short-term*), o qual inclui armazenamento (magnético) local, e longo período (*long-term*), o qual envolve meios de armazenamento óticos entre outros [Siegel and Kolodner, 1999] [Marques and et. al, 2004], e em alguns casos, em médio período. Existe uma diferença tremenda na velocidade de recuperação entre longo e curto período de armazenamento. Os armazenamentos típicos do PACS têm, a qualquer momento, pelo menos 95% de suas imagens no armazenamento em longo período, o qual é muito mais lento. É importante por isso utilizar algoritmos inteligentes para maximizar a possibilidade de se ter disponível os estudos e comparações requisitados em um armazenamento em curto período [Siegel and Kolodner, 1999].

O armazenamento local ou magnético, refere-se ao disco rígido (HD) do computador e armazena as informações da imagem digital em um disco magnético para uma recuperação rápida [Marques and et. al, 2004]. A maioria dos sistemas possui uma capacidade de armazenamento de curto período na faixa de 20 a 256 gigabytes [Siegel and Kolodner, 1999]. Um período curto de armazenamento deveria permitir a conservação das imagens por um período de pelo menos 2 a 3 semanas e deveria ter a capacidade de armazenar pelo menos de 1 a 3 meses de imagens, porém de modo geral, as imagens são mantidas armazenadas em um meio por volta de uma semana, devido ao grande volume de dados e o alto custo dos sistemas magnéticos de alta capacidade [Marques and et. al, 2004]. O tempo de recuperação deveria ser de 2 segundos ou menos para imagens CR e 10 ou menos segundos para 20 imagens de estudos CT, quando recuperando um estudo de um repositório de imagens central (uma ar-

quitetura PACS central) ou de uma estação de trabalho local (arquitetura PACS distribuída). Essas velocidades são necessárias para manter níveis aceitáveis de produtividade de radiologistas e médicos. O armazenamento local é utilizado tanto nas estações de visualização como também nos servidores do sistema [Marques and et. al, 2004] [Siegel and Kolodner, 1999].

Um período longo de armazenamento refere-se geralmente a discos óticos WORM (uma escrita, várias leituras). Esses discos possuem variados tamanhos e capacidades, podendo chegar a 10Gb cada e armazenam os dados em um formato de arquivo permanente e não apagável. Outras opções de armazenamento incluem arquivos em fita magnética, em CD-ROM, em DVD ou em disco ótico-magnético (M/O), que permite armazenar as informações por um período de tempo de um mês ou mais e então apagá-las quando não mais necessárias [Marques and et. al, 2004].

O armazenamento por longo prazo deveria ter a capacidade de armazenar pelo menos 5 ou 6 anos de imagens de estudos médicos. Esse período corresponde ao requisito que muitas instituições possuem de retenção de filmes convencionais. O tempo de recuperação de uma imagem de CR de um armazenamento de longo período deveria ser menos que 1 minuto e 30 estudos de imagens de CT deveriam estar disponíveis em 2 minutos. Para agilizar, um método deveria ser usado para transferir os exames antigos de um período longo de armazenamento para um de período curto, quando é provável que eles sejam requisitados, ou seja, após ter sido solicitado um novo exame nos sistemas HIS ou RIS, ou após a admissão do paciente no hospital, por exemplo. Esse processo é conhecido como “*prefetching*” e deveria resultar na obtenção prévia desses exames antigos.

A maioria dos sistemas PACS de grande escala utilizam uma *jukebox* ótica para armazenamento de longo período de imagens. A capacidade de armazenamento tipicamente varia de 20 gigabytes a mais do que 2 terabytes com tempo de recuperação na faixa de 20 segundos a aproximadamente 5 minutos para uma simples imagem de radiografia computadorizada (de 8 megabytes) [Siegel and Kolodner, 1999].

Em [Furuie et al., 1999] os armazenamentos são classificados como :

Online mídia *online* de até 100 GBytes suportando armazenamento de exames dos últimos 2 meses, considerando-se 5 Gbytes por dia de imagens (2.5 GB com compressão sem perda).

Nearline (dispositivos automáticos que permitem carregar e descarregar a mídia através de um robô, tais como *jukeboxes*, com até 3.4 TBytes). A recuperação *nearline* envolve descarregar automaticamente os arquivos DICOM para a mídia *online*, com um tempo

de pesquisa e carga de cerca de 3 minutos. O armazenamento *nearline* permite que as imagens mais recentes dos últimos 3 anos possam ser acessadas automaticamente.

Offline a recuperação *offline* é baseada em agendamento e carregamento prévio (prefetching) dos dados para a mídia *online*. Requer a intervenção do operador para carregar o exame ou a fita solicitada.

O gerenciamento desses armazenamentos é feito através de um sistema gerenciador de base de dados que mantém o controle da localização e movimentação das imagens, e dos estados, ou seja, se estão *online*, *nearline* ou *offline*, além de gerenciar a mudança de estado das imagens, ou seja, enviar imagens de um estado para outro, como por exemplo, do estado *online* para *nearline*, conforme ilustra a Figura 2.3.

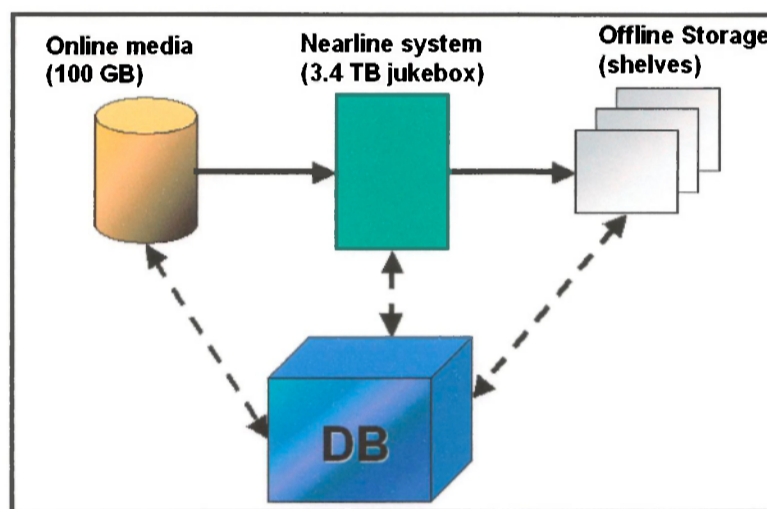


Figura 2.3: Armazenamento de um PACS combinando arquivamento *online*, *nearline* e *offline* através de um gerenciador de base de dados.

2.5 Exibição de Imagens

O sistema de exibição de imagens, ou a estação de trabalho, é o componente do PACS que tem recebido mais atenção. De fato, para a maioria dos usuários, é o único componente do PACS que eles irão interagir diretamente.

A estação de trabalho de imagens deve ser capaz de consultar as imagens e obtê-las rápida e facilmente, e permitir uma navegação rápida e intuitiva na base de dados, para permitir a obtenção e comparação de históricos relevantes ou exames relacionados. Os monitores de

exibição devem ter uma resolução de pelo menos 2000 por 1500 *pixels* para uso no diagnóstico de radiografias gerais e uma área de exibição comparável em tamanho a filmes convencionais de 14" por 17". O padrão de teleradiologia do *American College of Radiology* (ACR) sugere que as radiografias convencionais sejam visualizadas usando uma resolução de pelo menos 2k *pixels* [Siegel and Kolodner, 1999]. Uma outra sugestão é o uso de uma configuração de 2 ou 4 monitores. Quanto ao software de exibição e manipulação das imagens, deve ser intuitivo e de fácil uso e aprendizado [Siegel and Kolodner, 1999].

A navegação das imagens, ou a habilidade de recuperar e exibir imagens com a intenção de comparar exames atuais ou parecidos, tem sido relativamente desapontadora na maioria dos sistemas PACS, embora isso tenha melhorado consideravelmente durante os últimos 2 anos [Siegel and Kolodner, 1999]. Atualmente muitos passos são necessários para obter estudos antigos para comparação com os exames atuais, além de que muitos sistemas não suportam facilmente nem habilmente a comparação entre subníveis, tais como seqüências individuais de imagens MRI com imagens de outros exames [Siegel and Kolodner, 1999].

A tendência futura é a existência de um contínuo aumento na velocidade de gráficos e na atuação global das estações de trabalho utilizadas para a exibição das imagens, permitindo assim uma manipulação mais rápida das imagens, e no uso de computadores pessoais como estações de trabalho, executando sistemas como o Windows NT [Siegel and Kolodner, 1999].

2.6 Rede PACS

As redes PACS podem ser vistas como uma estrada que tem sido construída para carregar imagens das modalidades de aquisição para os PACS, e dos PACS para as estações de trabalho, sendo a porta de comunicação do HIS/RIS e o arquivo de imagens. As redes podem ser projetadas utilizando-se ou uma arquitetura central ou distribuída [Siegel and Kolodner, 1999].

Em um PACS com uma arquitetura central, as imagens estão disponíveis utilizando dispositivos compartilhados de armazenamento de um curto período (tipicamente um RAID, ou um vetor de discos baratos). A vantagem dessa arquitetura é que todas as imagens de um período curto de armazenamento estão disponíveis em todas as estações de trabalho tipicamente com uma taxa de recuperação muito rápida. A desvantagem é a vulnerabilidade dessa configuração [Siegel and Kolodner, 1999].

Uma alternativa é um PACS com uma arquitetura distribuída, na qual as imagens estão armazenadas em múltiplos servidores distribuídos em todo o ambiente hospitalar. A

maior desvantagem é a necessidade de enviar as imagens automaticamente ou manualmente para os servidores individuais ou estações de trabalho, para obter uma atuação aceitável [Siegel and Kolodner, 1999].

As redes PACS devem ser capazes de suportar vários usuários simultaneamente, sem uma degradação significativa da rede. Devem também proporcionar um alto nível de segurança para garantir que somente usuários autorizados tenham acesso às informações dos pacientes. Uma das limitações com relação à atuação da rede é a infra-estrutura limitada dos hospitais, que têm sido tradicionalmente projetados para textos e números, e não para imagens [Siegel and Kolodner, 1999].

A implantação de uma rede PACS completa é um projeto bastante caro e complexo, sendo necessário o desenvolvimento de um planejamento bem organizado e inteligente para sua execução, principalmente devido à necessidade do ajuste das estruturas de rede de computadores geralmente inadequadas [Marques et al., 2000].

2.7 Serviço de Radiologia Digital (*filmless*) em Hospital Universitário

O Centro de Ciências das Imagens e Física Médica (CCIFM) da Faculdade de Medicina de Ribeirão Preto (FMRP/USP) vem trabalhando no sentido de iniciar o processo de transição do Serviço de Radiodiagnóstico do Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto para a radiologia *filmless*. Esse processo tem envolvido [Marques et al., 2000] [Marques et al., 2000]:

- conexão de equipamentos em rede (tais como Tomografia Computadorizada- CT e Ressonância Magnética Nuclear - RMN);
- armazenamento de imagens em meio eletrônico (CD-ROM) para posterior disponibilização;
- desenvolvimento e implantação de um Sistema de Informação em Radiologia (RIS), sobre o qual será desenvolvido este trabalho.

O departamento de radiologia do Hospital das Clínicas conta atualmente com os seguintes aparelhos DICOM compatíveis: 1 equipamento de Tomografia Computadorizada (CT), 1 de Ressonância Magnética Nuclear (RM) e 2 de ultra-som, conectados em rede, e gerenciados pelo sistema Magic View 300 da Siemens, que permite que um computador do tipo PC (com

sistema operacional Windows NT) funcione como um console auxiliar podendo manipular, arquivar e gravar em CD-ROM e disponibilizar imagens através do servidor. Os exames são gravados diariamente em CDs, que ficam guardados para consultas posteriores. Possui também um *disk-array* Data Force de 50Gbytes, o que possibilita disponibilizar imagens para consultas correspondentes a um período aproximado de 2 meses, porém está em fase de testes, e as imagens têm que ser recuperadas diretamente dos CDs.

Além disso está sendo configurado um servidor RSNA (*Radiological Society of North America*) que será utilizado como o servidor DICOM para os testes do PACS, utilizando a interface de visualização de imagens cujo desenvolvimento está descrito em [Caritá, 2002].

2.8 Sistema de Informação em Radiologia (RIS) do Hospital das Clínicas - HCFMRP

O RIS do HCFMRP, também denominado Sistema de Laudo Eletrônico (Figura 2.4), foi desenvolvido e implantado em parceria entre o Centro de Ciências das Imagens e Física Médica (CCIFM) da Faculdade de Medicina de Ribeirão Preto (FMRP/USP) e o Centro de Informações e Análises do Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto (HCFMRP), e está em uso desde 1999 [Marques et al., 2000].

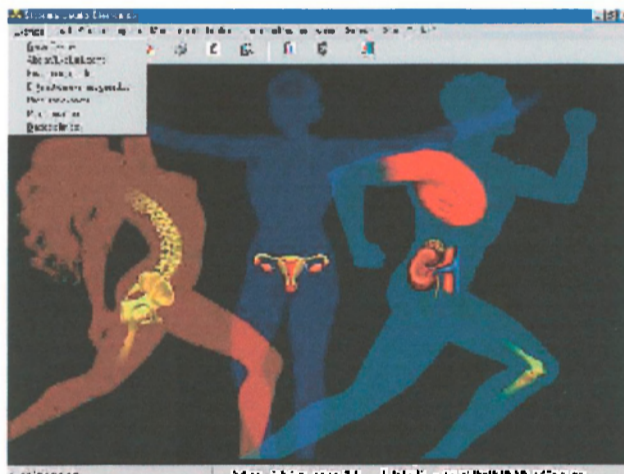


Figura 2.4: Tela principal do Sistema RIS do HCFMRP.

O sistema foi desenvolvido com a finalidade de otimização no processo de disponibilização e consulta de laudo através da rede *ethernet* do hospital, uma vez que existia um tempo de espera de três a quatro dias para a disponibilização dos laudos no Serviço de Arquivo

Médico (SAM). Esse tempo era necessário, pois os laudos eram emitidos de forma manual em um formulário que acompanhava o pedido de exame, sendo conferidos posteriormente pelo especialista, encaminhados para digitação, impressos, corrigidos, re-impressos, assinados e finalmente encaminhados ao SAM, conforme esquematizado na Figura 2.5. Existia uma procura bastante alta no Setor de Radiodiagnóstico por laudos ainda não disponíveis no SAM. Com a implantação do RIS esse tempo de espera foi bastante minimizado, uma vez que, assim que os exames são laudados, eles já se encontram disponíveis para consultas *online* além de que o mesmo passa a ser impresso diretamente no SAM, utilizando assinatura eletrônica, agilizando assim o processo de distribuição destes junto aos prontuários dos pacientes [Marques et al., 2000].



Figura 2.5: Esquema do processo global do RIS ilustrando o fluxo de um exame radiológico [Rosa, 2002].

O núcleo do sistema é o exame, ao qual estão associados um número de identificação e outras informações referentes ao paciente, tipo de exame e região anatômica, sala e aparelho de sua realização, técnica utilizada, quantidade de exposições realizadas, quantidade de filmes utilizados, quantidade de filmes rejeitados e o motivo de rejeição, laudos e médicos responsáveis pelos laudos (residente e supervisor). O programa permite a emissão de relatórios de produtividade e técnicos, facilitando o gerenciamento e controle da qualidade do serviço. O RIS trabalha sobre uma plataforma de base de dados ORACLE, com interface ao usuário feita em DELPHI, permitindo consulta *online* de laudos através de microcomputadores conectados à rede *ethernet* do Hospital [Marques et al., 2000].

O processo global do sistema pode ser descrito conforme a Figura 2.5, e inicia-se com a solicitação de um exame para um paciente junto ao serviço de agendamento do hospital.

É gerado então uma etiqueta contendo um código de barras com o número de registro HC do paciente e a clínica solicitante, que o técnico irá utilizar, no momento da realização do exame, para gerar eletronicamente o exame no sistema através da leitura desse código de barras e da inserção manual de informações referentes ao tipo de exame, região anatômica, técnica empregada, sala de realização, reveladora utilizada, tipo e quantidade de filmes expostos, se houve rejeições e o motivo. Após a realização do exame e sua geração eletrônica no sistema, os filmes são encaminhados para uma sala de leitura para serem avaliados e laudados, inicialmente como provisórios pelos médicos residentes, e posteriormente conferidos e corrigidos, se necessário, pelos médicos especialistas e então gravados como definitivos. Os laudos definitivos são impressos diretamente no Serviço de Arquivo Médico (SAM) para serem incluídos no prontuário do paciente. Os laudos gerados podem ser consultados on-line através de qualquer computador disponível no hospital, sem a possibilidade de alteração dos laudos. Essa consulta, feita através do fornecimento do registro do paciente ou nome, exibe uma lista com todos os exames do paciente, suas condições (não laudados, laudados provisórios ou definitivos), bastando então selecionar o exame de interesse para acessar seu laudo. Pode-se também fazer uma busca por patologia, cuja pesquisa será feita pesquisando palavras-chave presentes nas descrições dos laudos de exames realizados dentro de um período estabelecido pelo usuário [Marques et al., 2000].

De modo geral, pode-se dividir o RIS em quatro módulos principais [Marques et al., 2000]:

Módulo de Exames: módulo que permite gerar, alterar, excluir ou mesmo consultar exames realizados.

Módulo de Geração de Laudos: gera laudos provisórios e definitivos para os exames gerados no sistema.

Módulo de Consultas de Laudos: permite consultas à lista de exames e respectivos laudos dos pacientes (busca por registro ou nome do paciente fornecido) além de consultar por patologias todos os laudos que contenham em sua descrição palavras-chave fornecidas.

Módulo de Gerenciamento: permite a emissão de relatórios técnicos (consumo de filmes, rejeição de filmes e suas causas, rejeição por reveladora, por sala ou por equipamento, e outros), administrativos (número total de exames realizados, exames por modalidade, por técnicos, exames laudados por médico, laudos atrasados, e assim por diante).

A segurança do sistema é garantida através do acesso restrito a cada módulo do sistema de acordo com os direitos atribuídos a cada um dos usuários cadastrados. Cada usuário possui direitos específicos, de acordo com sua função dentro do fluxo de atividades do serviço e, para ter acesso ao sistema, o usuário necessita informar seu nome de usuário e sua senha. Toda operação realizada pelo sistema fica armazenada em conjunto com o código do usuário solicitante.

O Sistema de Laudo Eletrônico contém atualmente somente informações textuais, porém em [Caritá and Marques, 2000] [Caritá, 2002] foi desenvolvido um projeto piloto para vinculação, recuperação e visualização das imagens dos exames de Ressonância Magnética e Tomografia Computadorizada do HCFMRP/USP. O processo de vinculação das imagens consistiu em extrair as informações dos exames, necessárias para relacionar as imagens com os exames do RIS, contidas nas “tags” dos arquivos DICOM das imagens, e inseri-las automaticamente na base de dados responsável pelo gerenciamento das imagens. Na base de dados as imagens são armazenadas no formato DICOM original [Rosa, 2002].

Uma das grandes contribuições do trabalho de vinculação das imagens com os exames radiológicos do RIS foi a utilização de uma *tag* do DICOM para armazenar a chave do exame no RIS. Com isso, adotou-se um padrão para a realização dos exames e aquisição das imagens: os técnicos entram com as informações do exame no RIS, que irá gerar um número único de identificação do exame. Esse número é então inserido manualmente junto com as demais informações do paciente nas *tags* dos arquivos DICOM das imagens. Sendo assim, as novas imagens adquiridas contêm em seu interior, o número do exame que permite vinculá-las ao RIS [Rosa, 2002].

Foi a partir do RIS e da utilização do novo protocolo para a realização dos exames, além da conscientização dos técnicos e médicos da importância de preencher corretamente as informações do paciente, principalmente a chave do exame (RGIIC), que o SRIS-HC¹ foi desenvolvido originalmente.

2.9 Conclusão

Os atuais PACS de larga escala estão começando a se beneficiar do tremendo avanço nas tecnologias de rede e computadores. A radiologia sem filme proporciona uma alteração radical no modo como o diagnóstico em radiologia é praticado, o que resultará em uma completa remodelagem das salas de leitura dos radiologistas e a localização das áreas de

¹Sistema de Recuperação de Imagens por Similaridade do Hospital das Clínicas.

leitura dos radiologistas no hospital e em todas as empresas de saúde.

No futuro os PACS se tornarão diretamente integrados com as empresas de tratamento de saúde, resultando na disponibilidade dos registros médicos eletrônicos dos pacientes bem como uma vasta biblioteca de imagens e texto. Haverá acesso instantâneo a qualquer imagem do sistema de saúde a qualquer momento, com uma melhor segurança das imagens e uma qualidade mais alta e mais imagens de diagnósticos, e uma nova geração de ferramentas para os radiologistas. Essas ferramentas irão permitir aos radiologistas melhorar a qualidade das imagens existentes e combinar múltiplas imagens de uma ou mais modalidades em uma única imagem ou estudo para melhorar a exatidão do diagnóstico. Finalmente, um novo conjunto de características de suporte a decisão estarão disponíveis no futuro, que usará informações clínicas do registro eletrônico médico em conjunto com as imagens da base de dados dos radiologistas e irá combiná-las com as informações clínicas e imagens associadas com um novo estudo para ajudar a encontrar ou mesmo sugerir o diagnóstico.

Uma vez que as imagens médicas ainda não estão integradas ao Sistema de Informação em Radiologia - RIS, e nem intermodalidades, as soluções isoladas adotadas pelo Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto não caracterizam um PACS completo, mas sim um resultado inicial de um projeto de pesquisa que visa a implantação de um serviço de radiologia sem filme junto ao hospital.

Extração de Características de Imagens

3.1 Considerações Iniciais

A extração de características utilizando histogramas é o ponto central deste trabalho. Com o processamento de histogramas, será gerado um espaço baseado nos vetores de características (*feature vectors*), a serem utilizados para indexação e recuperação de imagens.

Um **vetor de características** é uma representação numérica sucinta de uma imagem ou parte da imagem (um objeto) representando medições sobre seus aspectos representativos. O vetor de características é um vetor n -dimensional que contém essas medidas. Essa nova representação da imagem pode ser armazenada em uma base de dados e assim permitir uma recuperação rápida da imagem. O objetivo central deste capítulo é : *Dada uma imagem, ou uma região dentro da imagem, gerar as características que representem esta imagem, as quais serão organizadas numa estrutura de indexação métrica*, para o qual tem-se que considerar os seguintes aspectos do processo [Loew, 2000]:

- Reduzir a dimensionalidade dos dados.
- Ressaltar propriedades da imagem para facilitar a percepção humana.
- Tratar os aspectos de invariância às transformações da imagem.

Neste Capítulo será descrito o funcionamento dos extratores de características. Será dada uma introdução sobre as características de imagens e seus principais atributos, seguida das consultas por similaridade e a classificação das estruturas métricas.

3.2 Definindo uma Imagem

As imagens são representadas como conjuntos de elementos (*pixel*) que são colocados em uma grade regular. Os valores associados a cada *pixel* são aqueles obtidos do processo de quantização e correspondem ao valor de intensidade (brilho), no caso de imagens monocromáticas. Assim, formalmente, uma imagem pode ser definida da seguinte forma:

Definição 3.1 - *Uma imagem A é uma função definida sobre uma faixa bidimensional $G = [0, x_0] \times [0, y_0]$ tomando valores no conjunto de possíveis luminosidades $V = [0, v_0]$. Isto é, $A = \{(x, y, v(x, y)) / (x, y) \in G \text{ e } v \in V\}$.*

Um histograma de imagem é composto por um número de *bins* que depende da resolução de quantização da imagem. Geralmente este valor é dado em potência de 2, isto é: 64, 128, 256, etc. De qualquer forma, para o olho humano, é difícil enxergar os detalhes e diferenças nas intensidades e, na prática, $v_0 = 32$ ou 16 é suficiente para representar as imagens [Theodoridis and Koutroumbas, 1999]. Em imagens médicas, dentro de um mesmo domínio, usualmente este valor é fixo. Formalmente, um histograma pode ser explicitado através da seguinte definição:

Definição 3.2 - *O histograma normalizado $HN_A(z)$ de uma imagem A fornece a frequência de cada valor de intensidade z na imagem, a qual é dada em porcentagem. O histograma normalizado de uma imagem com t níveis de intensidade é também representado por um vetor com t elementos.*

Deve-se observar que o histograma normalizado é invariante em relação às transformações geométricas (escala, rotação e translação). Seria interessante conseguir um histograma que fosse também invariante em relação às transformações lineares de brilho. A Figura 3.1 apresenta uma imagem de tomografia de cabeça humana e o histograma normalizado dessa imagem. Os histogramas normalizados permitem comparações entre imagens de qualquer tamanho, assim, transformações geométricas realizadas sobre as imagens fontes fornecerão os mesmos histogramas.




Figura 3.1: Uma imagem e seu histograma normalizado.

A necessidade de gerar vetores de características se faz necessária pela dificuldade de poder trabalhar com o total de informação da imagem, que são dados muito grandes. Por exemplo, para uma imagem de dimensão 64×64 , o número de *pixels* é de 4096. Para o caso de sistemas de recuperação de imagens baseado em conteúdo, este número é muito alto, além disso a comparação *pixel a pixel*, em muitos casos, não é significativa. Então a geração do vetor de características é um processo que calcula novas variáveis a partir da imagem original $A(m, n)$. Este processo procura gerar características que tragam informações a respeito da imagem (ou objetos da imagem).

3.3 Atributos das Imagens

Muitos dos sistemas de recuperação de imagens utilizam a forma, textura e cor para representar uma imagem [Stehling et al., 2000], [Krishnamachari and Abdel-Mottaleb, 1998] [Chua et al., 1997]. Sua recuperação está baseada na similaridade das características derivadas delas. Embora a cor seja um atributo confiável na recuperação de imagens, situações onde a informação de cor não as discrimina bem requerem o uso de atributos de forma e/ou textura para a recuperação de imagens. Além disso, os sistemas baseados num único atributo da imagem podem não alcançar níveis de recuperação adequados, motivo pelo qual os sistemas procuram utilizar múltiplos atributos das imagens para a sua indexação e recuperação [Vailaya, 2000].

3.3.1 Cor

As cores presentes em uma imagem possuem um papel significativo na sua indexação e recuperação. Existem diferentes representações de cores que incluem desde o tradicional RGB (*red, green, blue*), o modelo mais simples que mapeia diretamente as características físicas do dispositivo de exibição, até o HSI (*hue, saturation, intensity*) que reflete mais precisamente o modelo de cores para a percepção humana.

Muitos trabalhos recentes de extração de características baseadas em distribuição de cores estão concentrados nos histogramas de cor¹. Alguns dos trabalhos da literatura incluíram a indexação de cor usando intersecção de histogramas [Swain and Ballard, 1991] [Moghaddam et al., 2000], assinaturas [Chua et al., 1997] [Rubner and Tomasi, 2000] e o trabalho recente de [Bueno, 2002] produz uma função linear por partes baseada em histogramas, que foi nomeada de Histogramas Métricos, sendo utilizados na recuperação de imagens similares. Os histogramas de cor são invariantes à translação e rotação das imagens, sendo que, com a normalização dos histogramas, obtém-se também a invariância à escala. De qualquer forma, os histogramas de cor não indicam a localização espacial dos *pixels* na imagem, podendo trazer incoerência entre semelhança de imagens, como visto na Figura 3.2. Outras abordagens como a recuperação baseada em distribuição espacial de cores [Yamamoto et al., 1999] [Moghaddam et al., 2000] eliminam esse tipo de incoerência, mas aumentam o custo computacional por utilizarem diversos histogramas em suas consultas.

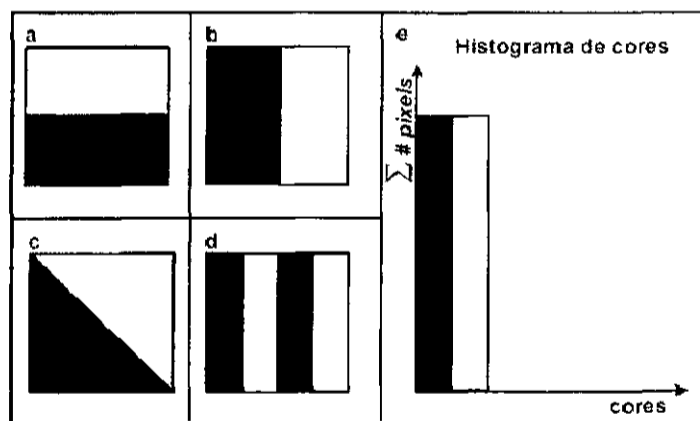


Figura 3.2: Exemplos de imagens diferentes (*a, b, c e d*) que possuem o mesmo histograma de cores (*e*).

Esta abordagem apresenta algumas dificuldades pelo próprio caráter não invariante do

¹Para imagens monocromáticas, histogramas de cor são correspondentes aos histogramas de brilho ou intensidades.

histograma de cores. Além disso, se a imagem contém um número alto de cores, então o vetor de características será maior e a indexação de vetores com tal dimensão se torna problemática.

3.3.2 Textura

Não existe uma definição clara de textura, mas os autores concordam em defini-la como as mudanças na intensidade da imagem que formam determinados padrões repetitivos [Tuceryan and Jain, 1993]. Uma textura é um padrão visual onde há um grande número de elementos visíveis arranjados de forma equânime com densidades variadas. Um elemento de textura é uma região de intensidade uniforme de formas simples que se repete dentro de um intervalo, como exemplificado na Figura 3.3. Assim, uma textura pode ser analisada dentro de um intervalo (janela), denominada “análise estatística”. Se o procedimento for realizado no elemento da textura, é então denominado “análise estrutural”. Geralmente, utiliza-se a análise estrutural sempre que os elementos da textura possam ser claramente identificados. Por outro lado, aplica-se a análise estatística para texturas pequenas e não muito regulares.




Figura 3.3: Exemplo de texturas.

Medidas estatísticas buscam caracterizar a variação de intensidade em uma janela de textura. Exemplos de tais medidas são **contraste** (alto contraste: textura de pele de zebra, versus baixo contraste, textura da pele de um elefante); **granularidade** (tamanho dos elementos do padrão) e **direcionalidade** (estampa de padrão de xadrez em um tecido versus um padrão liso). Uma ferramenta para a manipulação de padrões estatísticos é o espectro de Fourier. Através da transformada de Fourier realizada sobre uma janela de textura gera-se uma assinatura. Janelas que possuam assinaturas próximas ou bastante similares podem, então, ser agrupadas.

A análise estrutural de texturas obtém os elementos de textura presentes na imagem, determinando seus formatos e estimando as regras de posicionamento. As regras de posicionamento descrevem como os elementos de textura são colocados com relação aos demais, além de estabelecer o relacionamento de vizinhança (conexidade), o número de elementos por unidade espacial (densidade) e sua regularidade (homogeneidade).

Estas características servem como medida para a diferenciação de texturas que não seguem um determinado padrão de repetitividade, fornecendo informações relevantes para a classificação.

O tratamento de textura difere do realizado sobre cores devido ao fato de que as texturas são definidas sobre janelas ou regiões da imagem e não sobre *pixels*, como as cores. A segmentação de uma imagem utilizando textura determina quais regiões possuem textura uniforme. Depois que as regiões são determinadas, os retângulos que as envolvem (*Minimum Bounded Box - MBB*) podem ser utilizados para construir uma estrutura de indexação tipo R-Tree [Guttman, 1984].

Em [Haralick et al., 1973] é descrita uma metodologia de classificação de imagens a partir do uso da abordagem estatística de segunda ordem, onde são definidas diversas características advindas do cálculo de matrizes de co-ocorrência, que são matrizes que contam as ocorrências de níveis de cinza em uma imagem. Essas matrizes são utilizadas para detectar uniformidade em imagens, classificando essas texturas. A utilização de texturas pode ser muito útil em sistemas hospitalares na detecção de tumores ou no diagnóstico através de imagens [Chan and McCarty, 1990]. Além disso, a textura é muito utilizada para realizar a segmentação de imagens médicas, como descrito em [Claude et al., 2001].

3.3.3 Forma

A recuperação de imagens baseada em forma é um dos problemas mais difíceis de serem tratados pelos sistemas de recuperação de imagens baseada em conteúdo. Isto se deve, principalmente, à dificuldade de segmentar automaticamente os objetos de interesse presentes na imagem, levando a recuperação por formas ser tipicamente limitada aos poucos objetos melhor discriminados que estão presentes na mesma.

A imagem a ser indexada deve ser pré-processada para possibilitar a busca e a determinação das bordas que estão nela presentes. Os filtros ou algoritmos de pré-processamento dependem do domínio da aplicação das imagens em questão. Objetos tais como tumores cerebrais e lesões de pele demandam um conjunto específico de algoritmos que são diferentes dos utilizados para localizar objetos como aviões, carros etc. Isto porque o primeiro domí-

nio de imagens não pode se valer de formas pré-definidas que possam auxiliar no processo de reconhecimento de informações morfológicas presentes na imagem. Por outro lado no segundo domínio, as imagens possuem formas baseadas em geometria, podendo-se valer da utilização de modelos descritos antecipadamente. O tratamento de imagens mais complexas demanda muitas vezes também o tratamento e remoção de ruídos em uma etapa de pré-processamento. A Figura 3.4 exemplifica a detecção de formas, onde são esperados a detecção do fígado, da espinha dorsal e do corpo. Qualquer objeto detectado dentro do contorno do fígado é considerado um tumor [Petraakis and Faloutsos, 1997].

Após o objeto ser encontrado, sua borda precisa ser detectada utilizando algoritmos de detecção de contorno. O processo de detecção de bordas e formas fica mais difícil e comprometido em cenas complexas onde há, além do ruído, oclusão parcial de objetos ou sombras sobre regiões das imagens.

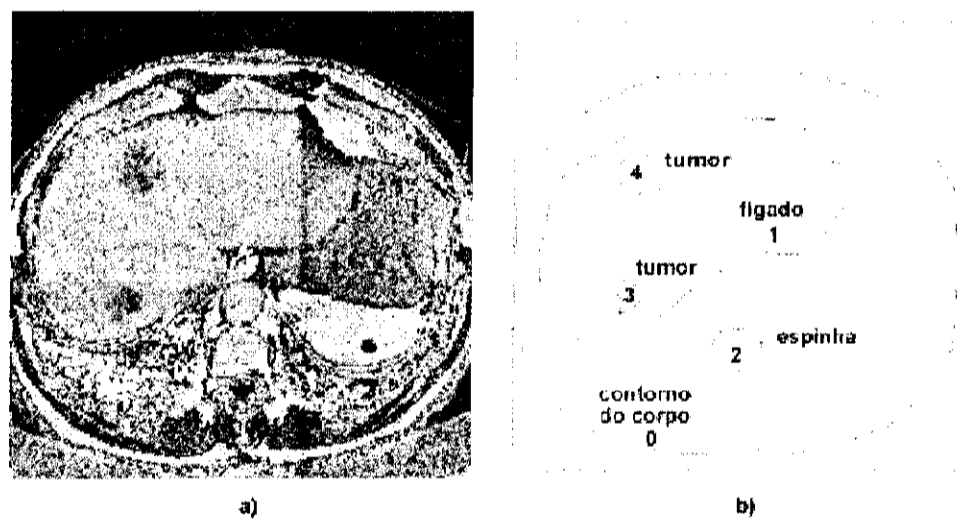


Figura 3.4: Exemplo de uma imagem original em tons de cinza (a) e sua forma segmentada mostrando 4 objetos identificados (b) [Petraakis and Faloutsos, 1997].

Os atributos de forma dos objetos presentes na imagem são também representados através de vetores reais embora aqui cada vetor possa ter uma dimensão². Nesse caso, um conjunto de vetores não tem uma dimensão característica apesar de poderem ser vistos como elementos de um espaço métrico e serem indexados dessa forma. Outra técnica é a de aproximar as formas encontradas por outras mais simples e fáceis de manusear. Por exemplo, a triangulação ou aproximação por retângulos de contorno (*bounding boxes*) podem ser utilizada para representar formas irregulares. Além disso, tem-se a vantagem de que os requisitos de

²espaços dimensionais serão tratados no Capítulo 4.

armazenagem são menores e a comparação fica mais simples, melhorando seu processamento.

3.3.4 Resumo das características de baixo nível das imagens

Na Tabela 3.1 são brevemente descritos os tipos de características de baixo nível da imagem que têm sido amplamente usadas na recuperação de imagens baseadas no conteúdo, considerando suas vantagens e limitações. Em termos de cor, a característica mais utilizada são os histogramas [Swain and Ballard, 1991] [Bueno, 2002], momentos [Stricker and Dimai, 1996] e vetores de coerência de cor [Pass et al., 1996]. Essas características descrevem as propriedades globais de uma imagem e podem ser facilmente extraídas. Uma grande limitação é a sua impossibilidade de representar adequadamente a informação de localização espacial ou de objetos na imagem. As características de forma suplantam essa deficiência e descrevem melhor os objetos da imagem. Pode-se descrever a forma e as características de contorno de objetos basicamente de três maneiras: por aproximação polinomial, por momentos invariantes e por descritores de Fourier. As características de forma outorgam um alto nível de abstração em termos do formato dos objetos numa imagem, mas isso requer o uso de bons algoritmos de segmentação para extrair objetos de interesse de uma imagem. As características de textura outorgam um nível intermediário de abstração numa imagem, assim como as características da cor. Ambas podem ser extraídas automaticamente de uma imagem, apesar da extração de textura ter maior complexidade computacional [Vailaya, 2000].

3.4 Importância da Extração de Características

A extração de características é o núcleo para a recuperação de imagens baseada em conteúdo. Estas características podem ser textuais (palavras chaves, anotações, etc.) e visuais (cor, textura, forma, faces, etc.). As características visuais podem ser gerais (cor, textura, forma) ou específicas para domínios (faces humanas, impressões digitais). Essas últimas podem abranger uma grande quantidade de conhecimento a respeito do domínio objetivado.

Considerando faces humanas como exemplo, as características mais utilizadas são as medidas de distância entre os principais componentes da face, tais como: separação entre centros e bordas dos olhos, boca, olhos, queixo e nariz.

A importância do processo de extração de características de imagens deve-se ao fato de que elas sintetizam propriedades inerentes da imagem, que serão utilizadas no processo de indexação e recuperação do conjunto de imagens [Traina, 2001].

Atributo da Imagem	Características da Imagem	Vantagens	Limitações
Cor	Histogramas, Momentos e vetores de co-ocorrência.	Podem ser extraídos automaticamente. Computacionalmente baratos. Representam as propriedades globais da imagem.	Não têm possibilidade de representar informações de localização espacial. Descrição limitada da semântica da imagem.
Textura	Matrizes de co-ocorrência, características de multi-escala e características de filtros de Gabor.	Podem ser automaticamente extraídos da imagem. Outorgam informação global assim como local.	Podem ser computacionalmente caros (extração e casamento de características) e difíceis de definir. Descrição limitada da semântica da imagem.
Forma	Aproximação poligonal, momentos invariantes e descritores de Fourier.	Consegue obter um alto nível de abstração em termos de forma dos objetos locais. Permitem consultas em nível de objetos.	Não podem ser automaticamente extraídos (precisam de bons algoritmos de segmentação para extrair os objetos de interesse). Computacionalmente caros para lograr invariância às mudanças do objeto rígido.

Tabela 3.1: Atributos de qualidade das características de baixo nível da imagem [Vailaya, 2000].

O processo de extração de características de imagens é apresentado na literatura da área de processamento de imagens como um dos passos para se efetuar o reconhecimento de padrões existentes em imagens [Theodoridis and Koutroumbas, 1999], [Gonzalez and Woods, 1993] e [Russ, 1995]. O reconhecimento de padrões assume que a imagem pode conter um ou mais objetos e que cada objeto pertence a um tipo (de um conjunto previamente definido de muitos tipos) e a uma ou mais categorias ou classes de padrões pré-determinados. Segundo Castleman [Castleman, 1996], dada uma imagem contendo vários objetos, o processo de reconhecimento de padrões consiste basicamente de três fases, exemplificadas na Figura 3.5:

- **Segmentação de imagem:** na qual cada objeto contido na imagem é localizado e isolado do resto da cena.
- **Extração de características:** quando são calculados valores que descrevam alguma

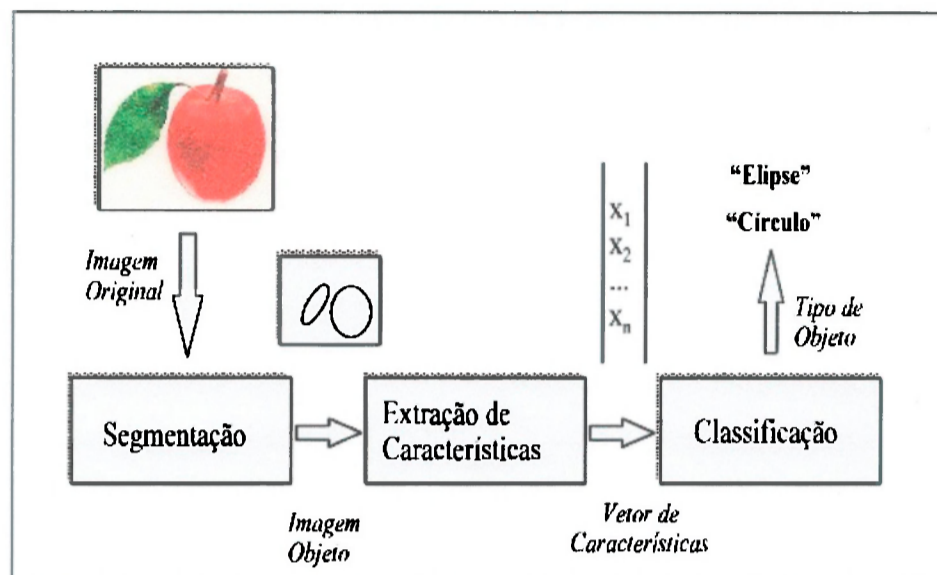


Figura 3.5: Etapas de reconhecimento de padrões de imagens.

propriedade quantitativa ou qualitativa dos objetos. Uma característica é uma função de uma ou mais medidas, calculadas de forma que quantifique alguma propriedade do objeto. Este processo produz um conjunto de n características que, juntas, formam o vetor de características de uma imagem. Pode-se então pensar em um espaço n -dimensional no qual todos os n -elementos deste vetor possam ser localizados. Assim, qualquer objeto corresponde a um ponto deste espaço, denominado espaço de características. Após uma imagem ser segmentada em regiões, geralmente convém representar e descrever o conjunto resultante de *pixels* segmentados em uma forma adequada para processamento. Há dois modos de representar uma região: baseando-se nas características externas (isto é, suas fronteiras) ou nas internas (os *pixels* contidos na região) [Gonzalez and Woods, 1993]. Geralmente, opta-se por uma representação externa quando o foco são as características morfológicas ou formas que estão presentes na imagem. Por outro lado, a representação interna é mais utilizada quando há interesse em propriedades refletivas, tais como cor e textura. Em ambos os casos é importante que as características selecionadas como descritoras sejam tão insensíveis quanto possível à variações de tamanho, translação e rotação.

- **Classificação da imagem:** O resultado desta etapa baseia-se na decisão a respeito da classe à qual pertence cada objeto da imagem. É reconhecido o tipo de cada objeto e o reconhecimento é implementado como um processo de classificação. Cada

objeto é associado a um dos diversos grupos pré-estabelecidos que representam todos os possíveis tipos de objetos que se espera existir na imagem.

Brown em [Brown, 1992] apresenta uma taxonomia sobre quais são os atributos mais utilizados no processo de extração de características e agrupa-os em cinco espaços. A Tabela 3.2 sumariza tais espaços e os atributos associados. É interessante notar que os atributos mais efetivos em sistemas de recuperação de imagens baseada em conteúdo, porém mais caros computacionalmente, são aqueles que usam características de bordas e características de alto nível [Smeulders et al., 2000], como grafos [Gudivada and Raghavan, 1995] [Petrakis and Faloutsos, 1997], e distribuição espacial de padrões [Petrakis et al., 2001].

Espaço de Características	Atributos
1. Intensidade Bruta (<i>raw intensity</i>)	Baseiam-se nas intensidades dos <i>pixels</i> .
2. Bordas	Estrutura intrínseca, menos sensível a ruídos. Incluem contorno e superfícies.
3. Características Salientes	Estrutura intrínseca, posicionamento preciso. Incluem intersecção de linhas, cantos, pontos de alta curvatura.
4. Características Estatísticas	Usa toda informação presente na imagem, bons resultados para transformações rígidas, suporte a suposições. Incluem momentos invariantes, eixos principais, técnicas como <i>singular value decomposition</i> e centróides.
5. Características de Alto Nível	Utilizam relações e informação de alto nível, bons resultados para <i>matching</i> local e impreciso. Incluem características estruturais (grafos de configurações de subpadrões) e sintáticas (gramáticas compostas a partir de padrões) e redes semânticas (regiões de cena e suas relações). Podem criar técnicas de assinatura para indexar imagens.

Tabela 3.2: Taxonomia sobre espaços de características extraídas de imagens [Brown, 1992].

As características estatísticas (histograma de intensidades, média, desvio-padrão, entre outras), por representarem um comportamento mais global da imagem e por serem mais baratas computacionalmente, são mais adequadas nos primeiros passos de seleção ou eliminação de candidatos. Já as características baseadas nas intensidades dos *pixels* em si, só valem quando se busca imagens exatamente iguais, o que não é o caso geral em consultas por similaridade.

3.5 Algumas Abordagens sobre os sistemas CBIR

Por obter a distribuição de cores ou níveis de intensidade de imagens com baixo custo computacional, histogramas de intensidade têm sido as grandes “vedetes” em sistemas de recuperação de imagens por conteúdo sendo utilizados em muitos deles. Nesta seção serão apresentados dois sistemas que serão utilizados neste trabalho. O Histograma Métrico foi usado no sistema base para a implementação deste trabalho, como poderá ser visto no Capítulo 5. A técnica BIC foi utilizada como suporte à comparação de resultados e, assim, verificar o desempenho do presente trabalho.

3.5.1 O Histograma Métrico

Uma abordagem de extração de características baseada em intensidade de cor foi tratada em [Bueno, 2002]. O Histograma Métrico (HM) reduz o número de *bins*, conservando a curva original do histograma, não trazendo perdas significativas de informação. Formalmente, o Histograma Métrico é definido como:

Definição 3.3 - *Um Histograma Métrico $HM_A(z)$ de uma imagem A é definido como $H_M(A) = \{N_A, \langle b_k, h_k \rangle \mid 0 < k < N_A\}$, que é um conjunto de N_A recipientes (*buckets*) formados por pares $\langle b_k, h_k \rangle$ consecutivos, onde b_k indica a largura e h_k a altura de cada recipiente.*

Um histograma normalizado é composto por um número de *bins* (conforme visto na definição 3.2). Este número depende da resolução de intensidades (luminosidade) da imagem, sendo um número fixo. Em um Histograma Métrico, o equivalente ao *bin* do histograma é chamado um *bucket*. Cada *bucket* corresponde a uma linha na aproximação do histograma normalizado. Os *buckets* não precisam ser regularmente espaçados. O número N_A de *buckets* em um Histograma Métrico depende do erro de aceitação no processo de aproximação da curva linear por partes sobre o histograma. Cada *bucket* k corresponde a dois pares consecutivos $\langle b_{k-1}, h_{k-1} \rangle$ e $\langle b_k, h_k \rangle$ para $1 \leq k \leq N_A$, onde $\langle b_k, h_k \rangle$ é o índice do *bin* mais à direita do histograma original representado no *bucket* k , e $\langle b_{k-1}, h_{k-1} \rangle$ é o valor normalizado do *bin* mais à esquerda representado no *bucket* k . Note que b_0 é sempre zero, pois é o início do Histograma Métrico. Para simplificar a notação, indica-se o recipiente b_k do Histograma Métrico da imagem A como A_{b_k} , e o valor normalizado h_k do Histograma Métrico da imagem A como A_{h_k} . A Figura 3.6 representa graficamente os *buckets* e os *bins* de um Histograma Métrico.

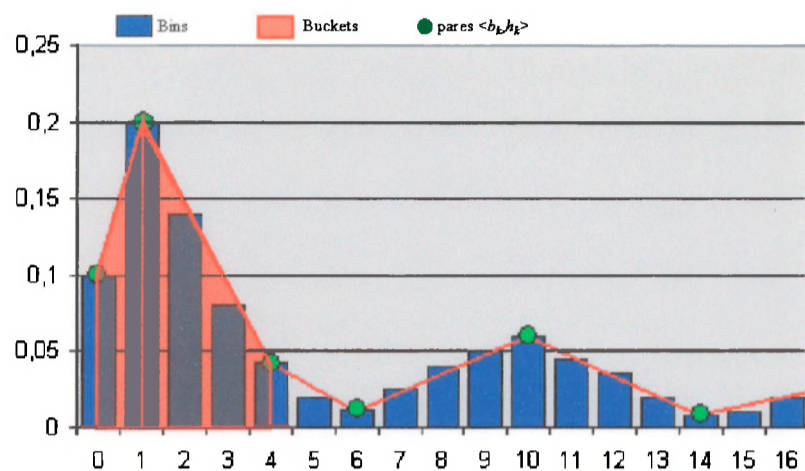


Figura 3.6: Histograma normalizado com os pontos $\langle b_k, h_k \rangle$ que definem os *buckets* e seu Histograma Métrico correspondente.

Para se obter um Histograma Métrico que mais se aproxime do histograma original, primeiramente é preciso obter os pontos máximos e mínimos da função que o representa. Através desses pontos a curva de aproximação sobre os mesmos é obtida. É importante observar que o número de *buckets* dos Histogramas Métricos, bem como sua largura, é variável e depende de características inerentes de cada imagem. Dessa forma, a comparação entre Histogramas Métricos não pode ser feita pelas funções de distância tradicionais, como é feito sobre histogramas convencionais. A Figura 3.7 exemplifica graficamente a implementação do Histograma Métrico.

Uma imagem com 8 *bits* por *pixel* possui um histograma normalizado de 256 (2^8) *bins* ou níveis de cinza. Em um conjunto muito grande de imagens, o seu processamento gera um custo computacional muito alto, tornando a resposta à busca lenta. Dessa forma, o surgimento do HM vem contribuir significativamente à redução desse custo.

Uma nova função de distância, denominada Distância Métrica $DM()$, foi desenvolvida para comparar Histogramas Métricos e se baseia no cálculo da diferença de áreas entre os dois histogramas [Traina et al., 2002a]. Os Histogramas Métricos e sua aplicabilidade em recuperação de imagens são apresentados em detalhes em [Bueno, 2002].

A Distância Métrica

Histogramas de imagens semelhantes possuem distribuições parecidas como pode ser visto na Figura 3.8. Normalmente, o cálculo de dissimilaridade entre histogramas é dado pelo somatório da diferença entre os *bins* de dois histogramas. Com relação aos Histogramas

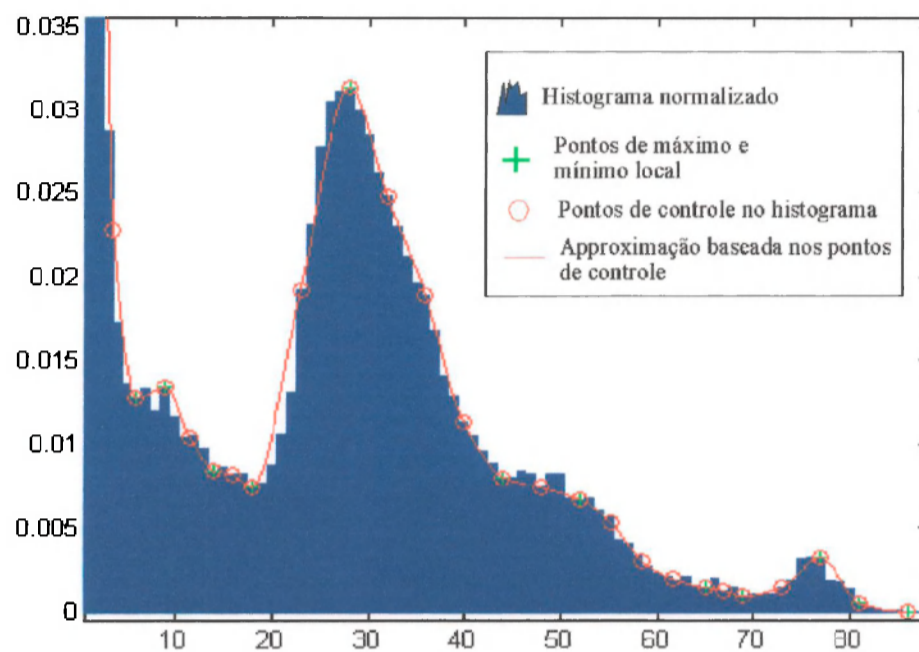


Figura 3.7: Obtendo o Histograma Métrico sobre o normalizado. Os pontos de controle são apresentados pelos elementos circulares e o Histograma Métrico pela curva que está ao redor do histograma normalizado.

Métricos a questão é como compará-los, uma vez que o número de *buckets* e a distribuição dos *buckets* de diferentes histogramas são variáveis. Os Histogramas Métricos, que possuem dimensionalidade variável, não permitem o cálculo de distância utilizando técnicas usuais como a Euclideana ou qualquer distância L_p [Wilson and Martinez, 1997], pois não é possível calcular a subtração dos pares de elementos dos vetores dos Histogramas Métricos para todos os pares de elementos. Por exemplo, como calcular a distância Euclideana entre um histograma com 30 *buckets* com largura variável de outro com 20? Isto porque, considerando os histogramas tradicionais como um conjunto de pares cartesianos, os valores em x serão sempre os mesmos para todos os histogramas, o que não ocorre com os Histogramas Métricos.

Portanto, para fazer o cálculo da distância entre Histogramas Métricos, foi desenvolvido um novo algoritmo baseado no cálculo da diferença entre histogramas, considerando que cada um deles ocupa uma área caracterizada pela distribuição de *pixels* e que a diferença entre estas áreas indica quão dissimilares são os histogramas.

Utilizando esta concepção, pode-se concluir que, quando dois histogramas similares são comparados, a diferença entre suas áreas de distribuição é pequena. Formalmente a distância

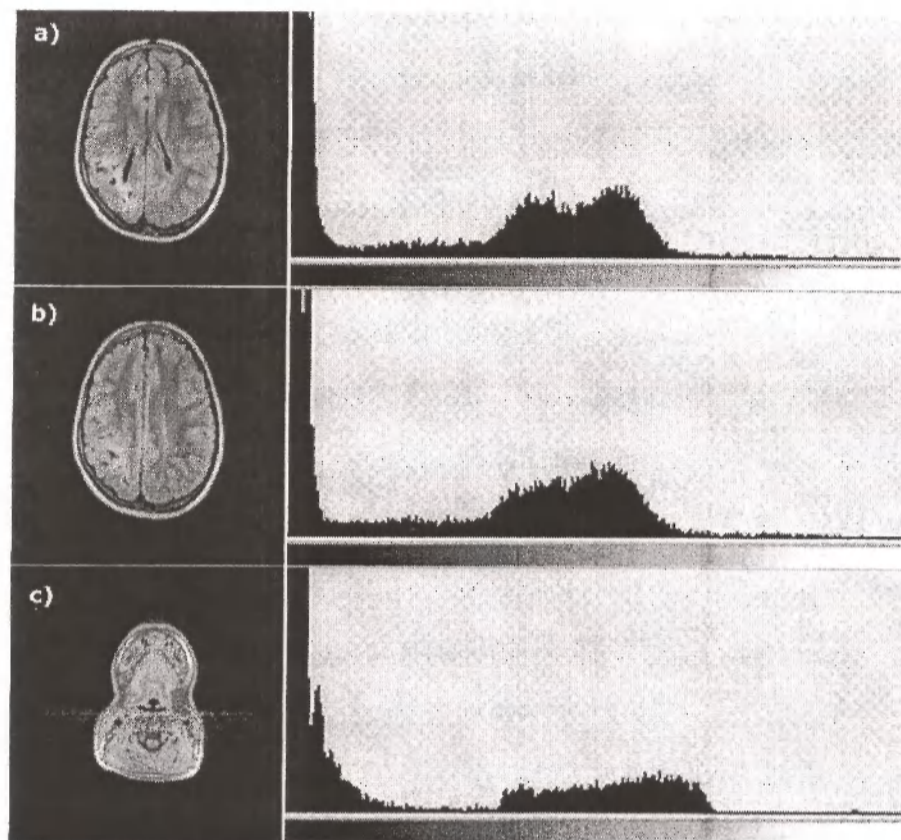


Figura 3.8: Imagem original (a), imagem mais semelhante (b) e imagem menos semelhante (c). Os histogramas apresentam a densidade de *pixels* para 256 níveis de cinza das imagens.

por diferença de área é dada por:

Definição 3.4 - A distância $DM()$ entre dois Histogramas Métricos $H_M(A)$ e $H_M(B)$ é dada pela área não sobreposta entre as duas curvas que representam os Histogramas Métricos, isto é:

$$DM(H_M(A), H_M(B)) = \int_0^{bm} |H_M(A, x) - H_M(B, x)| dx$$

onde $bm = \max(b_{NA-1}, b_{NB-1})$ e $H_M(\text{Imagem}, x)$ é a função contínua que representa o Histograma Métrico.

Ao realizar a soma das áreas, o processo encontra duas situações: quando existem áreas em formato de trapézio ou quando as áreas estão em formato triangular. Ao encontrar o trapézio ou o triângulo, o sistema realiza o cálculo da área e soma às áreas já calculadas

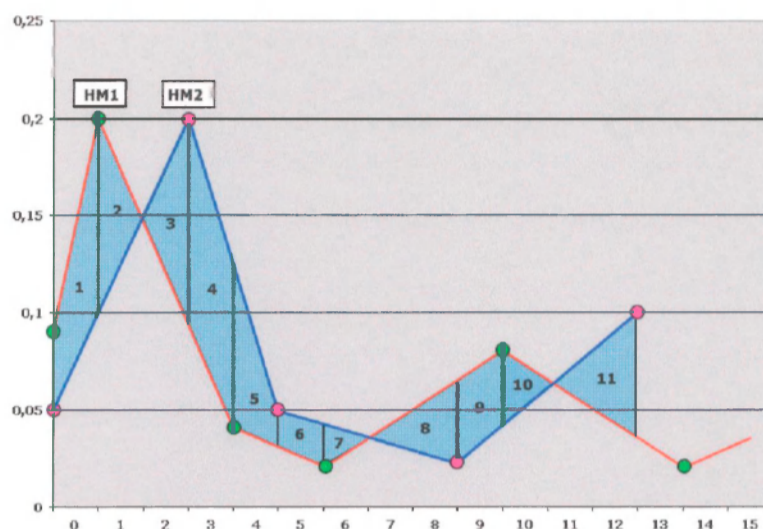


Figura 3.9: Distância entre dois Histogramas Métricos calculando a soma da diferença entre áreas.

anteriormente. Esse processo vai se repetindo até acabar um dos *buckets* do histograma. A Figura 3.9 fornece um exemplo de como calcular a distância entre dois Histogramas Métricos.

Note que o número de passos é maior ou igual ao número de *buckets* do histograma com menos *buckets*. Isso ocorre devido ao fato da largura dos *buckets* ser variável: em algumas ocasiões eles devem ser divididos, a fim de obter a área entre os dois histogramas considerados. Quando um dos Histogramas Métricos termina antes do outro, o cálculo da distância também pára.

3.5.2 Classificação de *Pixels* de Borda e Interior - A Técnica BIC

Em [Stehling et al., 2002] é proposto o BIC (*Border/Interior Pixel Classification*), uma abordagem para a recuperação de imagens por conteúdo em grandes coleções de imagens coloridas heterogêneas. A abordagem BIC utiliza técnicas simples, porém poderosas cujos resultados podem ser preservados durante as etapas do processo de recuperação de imagens. A abordagem BIC possui três componentes principais:

1. um algoritmo simples, eficiente e poderoso para a análise do conteúdo visual das imagens,
2. uma nova função de distância logarítmica para a comparação de histogramas de cores e

3. uma representação compacta para as características visuais extraídas das imagens.

O algoritmo de análise de imagens da abordagem BIC utiliza o espaço de cores RGB uniformemente quantizado em $4 \times 4 \times 4 = 64$ cores. Após a quantização do espaço de cores, é feita uma classificação binária dos *pixels* da imagem de entrada. Cada *pixel* é classificado como borda ou interior. Um *pixel* é considerado borda se ao menos um de seus quatro vizinhos (superior, inferior, direito e esquerdo) possui uma cor quantizada diferente da sua. Caso contrário, o *pixel* é classificado como interior. Após a classificação dos *pixels*, são calculados dois histogramas de cores: um considerando apenas *pixels* classificados como borda e outro, considerando-se apenas *pixels* classificados como interior. A Figura 3.10 exemplifica a classificação dos *pixels* de borda de uma imagem.




Figura 3.10: Análise de imagens pela abordagem BIC. Imagem original (esquerda). Classificação binária entre borda (preto) e interior (branco) (centro). (c) *Pixels* da borda com suas cores originais e os *pixels* do interior em branco (direita).

Os histogramas que representam as imagens na abordagem BIC são comparados utilizando-se uma distância denominada *dLog*. A função *dLog* calcula a diferença entre o logaritmo dos elementos do histograma. O objetivo dessa operação é reduzir o efeito negativo introduzido quando um único elemento do histograma possui valor muito alto. Este elemento do histograma, com valor muito alto, domina a diferença entre histogramas mas, em geral, tal elemento está associado ao fundo da imagem o qual possui pouca informação semântica e, como consequência, possui pouca importância no julgamento de similaridade feito pelo usuário. A função *dLog* atenua essa influência artificial e é definida como:

$$dLog(q, d) = \sum_{i=0}^{i < M} |f(q[i]) - f(d[i])| \quad (3.1)$$

$$f(x) = \begin{cases} 0, & \text{se } x = 0; \\ 1, & \text{se } 0 < x \leq 1; \\ \lceil \log_2 x \rceil + 1, & \text{caso contrário} \end{cases} \quad (3.2)$$

A utilização da função $dLog$ para comparar histogramas, além de aumentar a efetividade do sistema, permite armazenar os histogramas em metade do espaço originalmente necessário. Essa redução é possível armazenando-se o valor do log ao invés do valor original dos elementos do histograma. No caso da abordagem BIC, é possível representar o conteúdo visual de qualquer imagem em apenas 64 *bytes* de memória. Como consequência, é possível manter em memória principal as características visuais de grandes coleções de imagens, eliminando completamente a necessidade de métodos de acesso a disco para agilizar o processamento de consultas visuais.

3.6 Considerações Finais

Neste Capítulo foram descritas as principais propriedades de imagens digitais, assim como o processo de extrair características de imagens e algumas das principais técnicas. O sistema de extração de características pode ser considerado um primeiro passo para o armazenamento de imagens em um sistema de base de dados para imagens.

O maior problema, no que se refere ao processo de extração de características, é a procura daquele espaço de características mais representativo do domínio de imagens, para assim permitir a recuperação de imagens de maneira mais eficiente. A extração de histogramas possui grandes vantagens, dentre elas, o baixo custo computacional. Sua popularização em sistemas CBIR vem sendo bastante utilizada e muitas abordagens sobre o assunto surgem rapidamente.

Após a extração de características, é necessário agrupá-las com o intuito de realizar buscas rápidas e precisas. Para tanto, os conceitos sobre busca por similaridades e estruturas métricas se fazem necessários e serão descritos no próximo capítulo.

Consultas por Similaridade e Estruturas Métricas

4.1 Considerações Iniciais

Ao se trabalhar com a base de dados do cadastro de pacientes de um hospital, é comum recuperar dados considerando algum critério de filtragem. Um exemplo simples de consulta seria: levantar os resultados dos exames de todos os pacientes com dengue atendidos após o início do último verão. No caso, o critério é composto pela especificação de uma doença [doença = "dengue"] e de um intervalo de tempo [data atendimento > 21/12/2002]. A resposta fornecida pelo SGBD é composta pelos resultados dos exames em conformidade com as condições especificadas. Critérios como esse são caracterizados por envolver: igualdade, onde o interesse é por valores exatamente coincidentes; e ordem, onde o interesse é por valores maiores ou menores que um valor fornecido. Os tipos de dados em questão são tidos por convencionais e incluem, basicamente, valores numéricos (quantidades: datas, horas, etc.) e textuais (cadeias de caracteres: palavras, nomes, endereços, etc.).

No entanto, critérios baseados em igualdade e ordem são inadequados para bancos de dados que trabalham com tipos de dados complexos. Ou seja, não há sentido em realizar

consultas como por exemplo: obter o cadastro dos pacientes com tumor no cérebro cuja tomografia seja igual à do paciente em estudo. Dificilmente (provavelmente nunca) as tomografias de dois tumores serão exatamente iguais, mesmo que os tumores tenham a mesma classificação. O critério mais adequado para casos assim é o de similaridade. A consulta, então, faria mais sentido se definida como: obter o cadastro dos pacientes cuja tomografia se assemelhe à do paciente em estudo.

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 ou um valor positivo, que aumenta quanto maior for a distância (ou dissimilaridade) entre os objetos.

4.2 Tipos de Buscas por Similaridade

Como visto, as consultas por similaridade retornam objetos ordenados por semelhança. Este resultado é, em geral, obtido através de dois tipos de consultas: a **consulta por abrangência** (*range query*) e a **consulta aos vizinhos mais próximos** (*k-nearest neighbors query*). Tais consultas são definidas a seguir:

Definição 4.1 - Consulta por Abrangência (*range-query*) - *Dados um conjunto de objetos $O = \{O_1, O_2, \dots, O_n\}$ pertencentes a um domínio \mathcal{D} , uma função de distância métrica $d()$, um objeto de consulta $Q \in \mathcal{D}$ e uma distância de busca máxima $r(Q)$, a consulta por abrangência $\text{range}(Q, r(Q)) = \{O_i | O_i \in \mathcal{D} \text{ e } d(O_i, Q) \leq r(Q)\}$ seleciona todos os objetos O_i do conjunto de dados que estejam dentro da distância $r(Q)$ do objeto de busca.*

Um exemplo deste tipo de consulta seria: “Encontre as estrelas que estão até 10 anos-luz de distância do Sol”. Nesse caso o objeto de consulta é “Sol”, o domínio \mathcal{D} é o conjunto de estrelas do Universo e o raio de busca (distância máxima) é 10 anos-luz. A distância utilizada é a medida astronômica que mede o espaço em anos-luz.

Definição 4.2 - Consulta aos k Vizinhos mais Próximos (*k-nearest neighbors*), *k-NN* - *Dados um conjunto de objetos $O = O_1, O_2, \dots, O_n$ de um domínio \mathcal{D} , uma função distância métrica $d()$, um objeto de consulta $Q \in \mathcal{D}$ e um número inteiro $k \geq 1$, a consulta *k-NN* seleciona os k objetos do conjunto de dados que estão mais próximos de Q . Isto é, $k\text{-NN}(Q) = \{A_i | A_i \in \mathcal{A}, \mathcal{A} \subseteq \mathcal{O}, |\mathcal{A}| = k \text{ e } \forall A_i \in \mathcal{A}, O_i \in \mathcal{O} - \mathcal{A}, d(Q, A_i) \leq d(Q, O_i)\}$.*

Em caso de empate de distâncias na maior distância obtida, pode-se selecionar apenas o número necessário de objetos que satisfazem a regra ou criar uma lista de empates. Utilizando o exemplo anterior, a consulta “*Selecione as 5 estrelas mais próximas do Sol*” é uma busca *5NN* para o objeto “Sol” sobre o mesmo domínio de objetos da consulta-exemplo anterior.

A Figura 4.1 ilustra os dois tipos de consultas, sendo que a por abrangência, utiliza a distância Euclideana conhecida também como L_2 .



Figura 4.1: A consulta por abrangência (esquerda) seleciona todas as estrelas distantes de um raio r enquanto que a consulta aos vizinhos mais próximos (direita) seleciona as 5 estrelas mais próximas do elemento de consulta.

4.3 Métodos de Acesso Métricos

Os dois tipos de consultas por similaridade podem ser respondidos examinando todo o conjunto de dados, o que não é eficiente. Se não existir um índice para os dados, ou não for possível construir, então a busca seqüencial é a única maneira para responder às consultas. Um **algoritmo de indexação** é um procedimento para construir antecipadamente um índice projetado para minimizar o custo de acesso aos dados. O índice pode ser custoso de se construir em um primeiro momento, mas seu custo pode ser amortizado com a economia de cálculos de distâncias e acessos a disco sobre várias consultas na base de dados. Estruturas de indexação para espaços métricos (que englobam tanto dados espaciais com dimensão definida quanto dados adimensionais) foram propostas [Chávez et al., 2001] para dar suporte às buscas por similaridade.

Os **Métodos de Acesso Multidimensionais**, também conhecidos por **Métodos de Acesso Espaciais - MAE**, são utilizados para indexar objetos multidimensionais. Em geral,

um conjunto de objetos é dito multidimensional, ou n -dimensional, se um objeto qualquer desse conjunto pode ser localizado por uma série de n coordenadas. Os MAEs têm como premissa o fato dos dados manipulados pertencerem ao domínio dos dados espaciais ou a um espaço de dimensão n . Neste espaço, cada dimensão é representada por uma chave da relação.

Entretanto, para dados em espaços de altas dimensões, as MAEs não se mostraram muito eficientes, além de não suportarem a indexação de dados adimensionais. Desta forma estruturas de indexação métricas foram propostas com o objetivo de suprir esta deficiência. Estas estruturas, que foram chamadas de **Métodos de Acesso Métricos** - MAM, suportam buscas por similaridade em espaços métricos¹, onde a similaridade entre os dados é definida através de uma função de *dissimilaridade* ou também chamada de função distância métrica.

Os Métodos de Acesso Métrico, dão suporte natural às consultas por proximidade ou similaridade, além de se mostrarem eficientes para dados de dimensões altas. Dessa forma, é bastante apropriado utilizar um MAM para indexar imagens ou, mais especificamente, as características que foram extraídas das imagens, suportando consultas por similaridade. Com base nas características extraídas previamente da imagem, um MAM constrói a estrutura de índices calculando as distâncias entre elas, procedimento que deve corresponder à comparação entre as imagens originais.

Formalmente, um espaço métrico é um par $M = (\mathcal{D}, d)$, onde \mathcal{D} é o domínio do vetor de características - que são as chaves de indexação, e $d()$ é uma função distância métrica que satisfaz as seguintes propriedades:

1. **Simetria:** $d(O_i, O_j) = d(O_j, O_i)$;
2. **Não negatividade:** $0 < d(O_i, O_j) < \infty, O_i \neq O_j$ e $d(O_i, O_i) = 0$;
3. **Desigualdade triangular:** $d(O_i, O_j) \leq d(O_i, O_k) + d(O_k, O_j)$.

onde: O_i, O_j e O_k são objetos pertencentes ao espaço \mathcal{D} .

4.4 Estruturas Estáticas e Dinâmicas

As estruturas métricas estáticas não permitem inserções ou remoções posteriores à construção da árvore. É o caso das primeiras estruturas propostas (vp-tree,.mvp-tree, entre outras),

¹Espaços métricos englobam tanto dados espaciais com dimensão definida quanto dados adimensionais.

que apesar de terem sido desenvolvidas para dar suporte a consultas por similaridade, são estáticas.

A primeira estrutura métrica dinâmica (permite inserções e remoções após a construção da árvore), M-Tree [Ciaccia et al., 1997b], foi desenvolvida utilizando uma técnica de construção de baixo para cima (*bottom-up*), que ao mesmo tempo mantém a árvore balanceada e possibilita ainda novas inserções após a construção da árvore. A M-Tree possui dois tipos diferentes de nós:

- Nós internos, que armazenam o objeto centro deste nó e a distância dele para seu nó pai (essa distância não existe para o nó raiz da árvore), o raio de cobertura da região indexada por essa sub-árvore, e um vetor de ponteiros para suas sub-árvores.
- Nós folhas, que armazenam objetos, possuem seus identificadores de objetos (OIds) e o vetor de características que estão sendo utilizadas na indexação do conjunto de dados.

Neste projeto a estrutura a ser utilizada para armazenar as informações das imagens será a Slim-tree que, por ser dinâmica, permite inserções posteriores à criação da árvore.

4.5 A Slim-tree

Proposta por Traina et. al em [Traina et al., 2000], esta é a mais nova representante de estruturas métricas dinâmicas, sendo também uma estrutura balanceada e permitindo inserções posteriores à criação da árvore. A Slim-tree, 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 consultas por abrangência (*range queries*) e, portanto, também em tempo total de execução.

A Slim-tree possui tamanho fixo da página que armazena cada nó, e cada nó pode armazenar um número máximo de objetos C (Capacidade), e é constituída de :

- **nós internos** (*indexnodes*), cuja estrutura é representada por: **indexnode** [vetor de $\langle o_i, d(o_{rep}, o_i), Ptr(To_i), R_i, NEnt(Ptr(To_i)) \rangle$], onde o_i armazena o objeto que é o centro da sub-árvore apontada por $Ptr(To_i)$, e R_i é o raio de cobertura da região. A distância entre o_i e o objeto representativo deste nó $Rep(o_i)$ é armazenada em $d(o_i, Rep(o_i))$. O ponteiro $Ptr(To_i)$ indica o nó raiz da sub-árvore cuja raiz é o_i . O número de entradas presentes no nó apontado por $Ptr(To_i)$ é armazenado em $NEntries(Ptr(To_i))$. Na Figura 4.2 é possível visualizar a estrutura interna da Slim-tree.

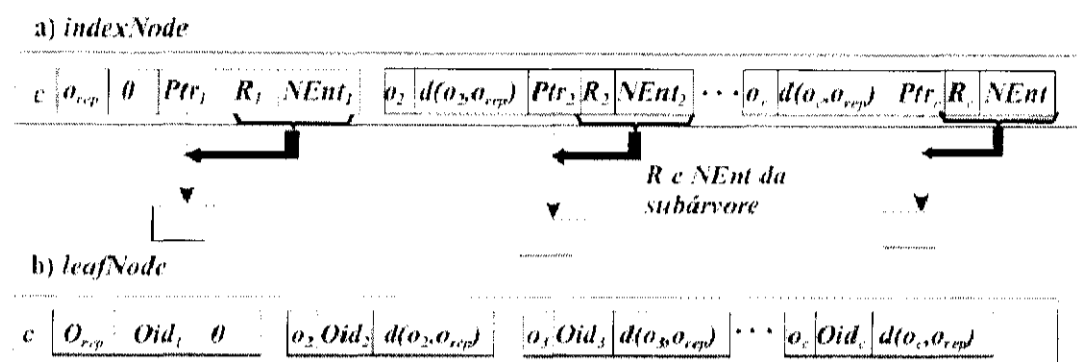


Figura 4.2: Estrutura lógica dos nós a) índice (**indexNode**) e b) folha (**leafNode**) da Slim-tree [Traina et al., 2000].

- **nós folha** (*leafnodes*), com estrutura representada por: **leafnode** [vetor de $\langle o_i, Oid_i, d(o_{rep}, o_i) \rangle$, onde Oid é identificador do objeto, o_i e $d(o_i, Rep(o_i))$ é a distância entre o objeto o_i e o objeto central (representativo) deste nó folha $Rep(o_i)$.

A Figura 4.3 fornece uma visão geral da organização de 17 objetos, rotulados de A até Q, armazenados numa Slim-tree de 3 níveis, onde a raiz encontra-se no nível zero e os objetos no nível das folhas (nível 2).

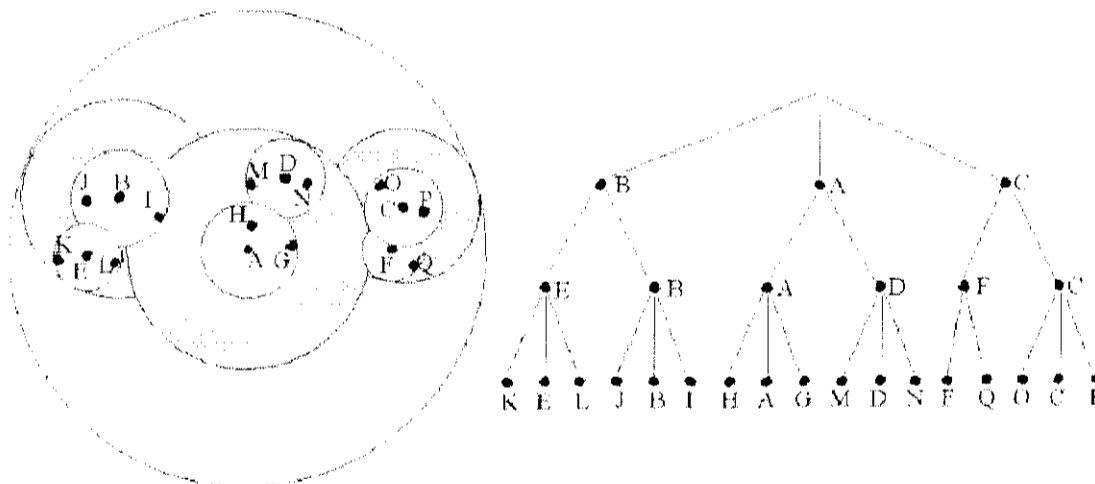


Figura 4.3: Representação da Slim-tree armazenando 17 objetos.

4.6 Inserção de Objetos na Slim-tree

A partir do nó raiz, o algoritmo tenta localizar um nó que possa receber o novo objeto. Se nenhum nó se qualifica, seleciona-se o nó cujo centro está mais perto do novo objeto. Caso mais de um nó se qualifique, é executado o algoritmo *ChooseSubtree* para selecionar o nó onde será inserido o novo objeto. Este processo é aplicado recursivamente para todos os níveis da árvore. Existem três opções para o algoritmo *ChooseSubtree*:

random seleciona aleatoriamente o nó para inserir o novo objeto entre os que se qualificaram.

mindist seleciona o nó cuja distância de seu representativo (centro) para o novo objeto seja a menor.

minoccup seleciona o nó que esteja com o menor número de objetos armazenados, dentre os que se qualificaram. O campo *NEntries* presente em todo nó intermediário (*indexnode*) da Slim-tree é utilizado pelo algoritmo *minoccup*, para selecionar o nó com menor valor de *NEntries*. Com o uso da opção *minoccup* do algoritmo *ChooseSubtree*, obtém-se árvores mais compactas (maior taxa de ocupação dos nós), redundando em um número menor de acessos a disco para responder consultas por similaridades.

Durante a inserção de objetos pode acontecer do nó escolhido já estar completo (com taxa de ocupação máxima), sendo necessário alocar um novo nó no mesmo nível do anterior, e os objetos que estavam nesse nó, mais o novo nó a ser inserido, devem ser então redistribuídos entre os dois nós. A Slim-tree cresce de um nível quando a raiz da árvore está completa e necessita-se inserir um novo elemento, pois a raiz divide-se e uma nova raiz deve ser criada com dois representativos, aumentando-se assim um nível da árvore.

A Slim-tree possui os seguintes algoritmos para efetuar a quebra de nós (*splitting*):

random - seleciona aleatoriamente os dois objetos representativos para os novos nós, e os demais objetos são distribuídos entre eles pela menor distância entre o objeto e o representativo, devendo-se respeitar a taxa de ocupação mínima dos nós.

minMax - consideram-se como candidatos representativos, todos os possíveis pares de objetos e, para cada par possível, associa-se os demais objetos a um dos representativos. O par de objetos que minimizar o raio de cobertura da sub-árvore será escolhido como representativo. Esse algoritmo tem complexidade $O(C^3)$, onde C é a capacidade dos

nós. Apesar de ser um algoritmo bastante custoso, ele consegue obter árvores que possibilitam consultas mais eficientes [Ciaccia and Patella, 1998].

MST - constrói-se a árvore do caminho mínimo (*minimal spanning tree* - MST) [Kruskal, 1956] e um dos arcos mais longos da MST é removido. Obtém-se assim dois agrupamentos, que serão os objetos associados a cada nó. A complexidade desse algoritmo é $O(C^2 \log C)$, com $O(C^2)$ cálculos de distância. Com o uso desse algoritmo é possível construir Slim-trees praticamente equivalentes às construídas com o uso do algoritmo de quebra de nós *minMax*, porém em muito menos tempo.

A Figura 4.4 ilustra o mecanismo de quebra de nós utilizando MST:

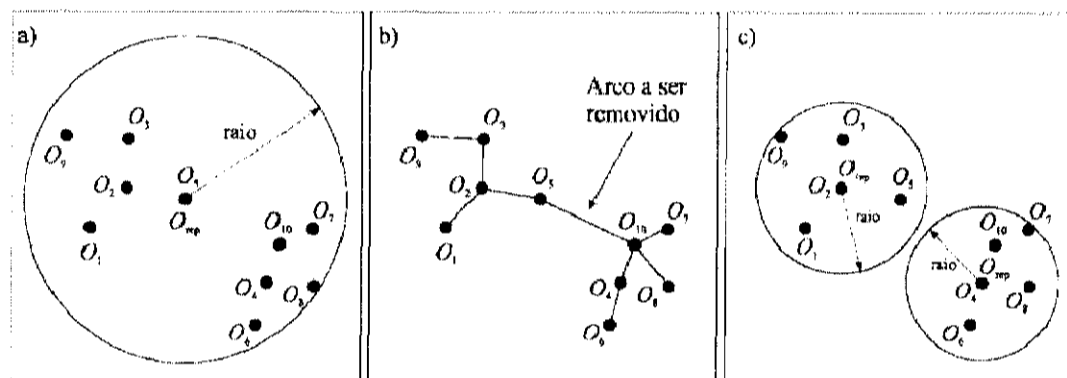


Figura 4.4: Mecanismos de quebras de nós do algoritmo MST.

4.7 Tratamento de Sobreposição

A sobreposição entre nós ocorre tanto nas estruturas métricas, quanto na maioria dos métodos de acesso espacial como, por exemplo, a família R-tree. Idealmente, os nós de uma árvore para indexação de dados não deveriam se sobrepor, permitindo podar todos os nós que não possuam objetos candidatos a responder consultas por similaridade, porém isso não ocorre e, assim como nos demais MAM, na Slim-tree os nós das regiões também podem ser sobrepostos.

O aumento de sobreposição entre os nós de uma estrutura de índices diminui sua eficiência em responder consultas, pois mais nós da árvore serão consultados (todos os que estão se sobrepondo à região de consulta) prejudicando a poda de sub-árvores. A Slim-tree foi desenvolvida com o objetivo de diminuir a sobreposição entre os nós da árvore, e também oferecer mecanismos para verificação da porcentagem de sobreposição existente na árvore.

Até a apresentação da Slim-tree, era considerado impossível medir a sobreposição entre nós em estruturas métricas [Ciaccia et al., 1997a]. Nos métodos de acesso espacial mede-se a intersecção calculando-se o “hiper-volume” da intersecção entre nós sobrepostos (como é feito na R*-tree [Beckmann et al., 1990]). Porém, em espaços métricos não há como calcular volume ou áreas, portanto na Slim-tree, ao invés de calcular o “volume” da intersecção entre nós sobrepostos, é computado o número de objetos que se encontram cobertos por mais de uma região (nó), obtendo-se a sobreposição entre dois nós internos de uma árvore métrica através do número de objetos cobertos por ambas as regiões (sub-árvores) dividido pelo número total de objetos presentes nas duas sub-árvores. Com isso, pode-se ter uma estimativa de quão apropriada ou boa é uma árvore para um conjunto de dados [Faloutsos and Kamel, 1994]. Tornou-se então possível definir o fator de sobreposição em uma árvore métrica através do *fat-factor* [Traina et al., 2002b], que no melhor caso (quando é zero) tem-se uma árvore ideal, sem sobreposições, cuja busca a um objeto já indexado deveria levar a acessar apenas um nó a cada nível da árvore, ou seja, para uma consulta pontual (uma consulta por abrangência com raio zero) em uma árvore ideal com, por exemplo, três níveis, somente três nós deveriam ser acessados. E no pior caso, quando todos os nós tivessem que ser acessados para responder à uma consulta pontual, o *fat-factor* é igual a um.

Pode-se medir a quantidade de sobreposição presente em uma dada árvore métrica T utilizando o *absolute fat-factor*. Porém ele não permite a comparação entre árvores diferentes construídas sobre o mesmo conjunto de dados, ou seja, métodos de quebra de nós ou opções do algoritmo de seleção de nós (*ChooseSubTree*) levam muitas vezes a árvores com número de nós M e altura de árvore H diferentes. Para permitir a comparação entre árvores distintas construídas sobre o mesmo conjunto de dados, fez-se necessário uma abordagem diferente, permitindo definir uma nova medida, o *relative fat-factor* que, ao invés de considerar o número de nós e a altura da árvore, considera o número de nós acessados para responder uma consulta pontual sobre todos os objetos da árvore real, sobre a altura e número de nós de uma árvore canônica (que possui o menor número possível de nós, ou seja, tem todos os nós completos, com a possível exceção de um nó em cada nível, e também com altura mínima).

Tanto o *absolute fat-factor* quanto o *relative fat-factor* estão diretamente relacionados com a taxa de sobreposição entre regiões do mesmo nível de uma árvore, sendo que o *absolute fat-factor* indica quão boa uma dada árvore é com respeito a sua quantidade de sobreposição, não se preocupando se os nós estão bem ocupados ou não, o que leva à otimização de espaço em disco se os nós estiverem com alta taxa de ocupação; enquanto que o *relative fat-factor*

permite a comparação entre duas árvores para o mesmo conjunto de dados, considerando tanto a quantidade de sobreposição quanto a ocupação eficiente de espaço em disco para armazenar os dados.

4.7.1 Reorganização dos Nós da Árvore - Algoritmo *Slim-down*

A reorganização permite melhorar uma árvore métrica já construída para um conjunto de dados. Através dos fatores de sobreposição *absolute fat-factor* e *relative fat-factor*, tornou-se possível verificar a quantidade de sobreposição entre nós da árvore e avaliar se tal árvore pode ser melhorada em termos de diminuição do número de acessos a disco para responder às consultas por similaridade. Com isso, se o desejável é que as árvores construídas apresentem o menor valor possível do fator *absolute fat-factor*, ou seja, que o número de objetos nas regiões de sobreposição seja o menor possível, o que um algoritmo de reorganização da árvore deveria fazer em primeiro lugar é diminuir o número de objetos nas intersecções de nós de mesmo nível; e em segundo lugar diminuir o número de nós da árvore. Foi então proposto em [Traina et al., 2000] o algoritmo *Slim-down*, que atua sobre uma árvore métrica já construída.

4.7.2 Visualização dos Dados Armazenados na Slim-tree

O módulo visualizador é uma ferramenta muito interessante anexada à Slim-tree, que permite “ver” o conjunto de dados indexado, juntamente com a estrutura de nós formada pela hierarquia da árvore, permitindo o tratamento de conjuntos de dados métricos adimensionais (por exemplo um conjunto de palavras) de uma forma mais intuitiva ou prática. O visualizador auxilia tanto na inspeção visual para verificação de como a árvore está, como em ferramentas para mineração de dados (*data mining*) visuais e interativas.

4.8 Considerações Finais

Como foi visto, as inovações da estrutura Slim-tree sobre as estruturas métricas tradicionais são: o *fat-factor*, que possibilita indicar se a estrutura de índices construída sobre um determinado conjunto de dados é eficiente ou não; o algoritmo *Slim-down*, que efetua a reorganização dos dados organizados por ela, de forma a minimizar a taxa de acesso a disco quando efetuando consultas por similaridade; possibilidade de visualizar a organização da informação armazenada, permitindo ao usuário perceber onde estão os aglomerados e

elementos de exceção pertencentes ao conjunto de dados, além do inter-relacionamento entre os elementos de dados, que possibilita também o acompanhamento visual das consultas efetuadas sobre a base de imagens.

Trabalho Desenvolvido

5.1 Considerações Iniciais

Os sistemas hospitalares trabalham com um grande volume de informação gerada muitas vezes por aparelhos distintos. Essas informações são basicamente os laudos dos pacientes, contendo, por exemplo: diagnóstico, medicação, sintomas e imagens de exames. A aquisição de imagens é realizada por equipamentos relativamente caros e de diferentes fabricantes. Como cada marca possui seu próprio meio para aquisição, imagens provindas de diferentes equipamentos comumente trazem diferenças entre elas. A alteração mais freqüente nas imagens é a variação de brilho (tonalidades de cinza). Esse tipo de alteração afeta profundamente os sistemas de recuperação de imagens baseados em cores.

Visando a solução para esse problema, foi realizada uma pesquisa bibliográfica sobre o assunto em [Campo, 2002]. As abordagens vistas trabalham com as cores das imagens e, em sua maioria, utilizam imagens coloridas em seu banco de imagens. Nenhuma das abordagens tratou, de maneira exclusiva, imagens em níveis de cinza e, muito menos, as de exames médicos. Como o Grupo de Bases de Dados e de Imagens - GBDI/USP estava trabalhando com o Histograma Métrico, sua modificação foi proposta em [Campo, 2002] e será apresentada neste capítulo.

O desenvolvimento do sistema proposto foi dividido em três etapas:

Pesquisa bibliográfica: onde foi verificado o estado-da-arte na área e possíveis soluções, além do estudo das bibliotecas e aplicativos que foram utilizados.

Protótipo: onde foi implementado e testadas algumas soluções descritas na seção 3.5.1 e 3.5.2, além de inserir novos recursos para a manipulação e tratamento de imagens.

SRIS-HC: implementação do sistema final, incorporando partes do protótipo ao Sistema de Recuperação de Imagens Similares do Hospital das Clínicas de Ribeirão Preto.

5.2 Protótipo de um SRIS baseado no DicomViewer

Quando um cliente observa a necessidade de fazer um software, ele tem um objetivo final, mas raramente todos os requisitos estão bem definidos e claros para o programador. Há sempre a necessidade de inclusão de algum requisito, ou da portabilidade, ou ainda mesmo a interface com o usuário [Pressman, 2002].

A prototipação é um método que o programador utiliza para poder encontrar a melhor alternativa, os requisitos e os dados necessários para a construção do melhor programa para o usuário. Existem três possibilidades distintas:

1. Um rascunho, desenho em um papel, que demonstre a interatividade com o usuário, e também os resultados que o programa trará.
2. Um protótipo que tenha algumas funções (algoritmos) que executem o procedimento requerido pelo usuário, como forma de demonstração de desempenho parcial, demonstração de solução do problema, ou algo do gênero.
3. Um programa que execute parte ou toda a função requerida pelo usuário apenas como demonstração, como por exemplo, relatórios, mas que causarão um esforço de programação posterior para a melhoria do mesmo.

Primeiramente, um protótipo foi criado para a realização de testes e validação de abordagens. O sistema foi desenvolvido tendo como base o software DicomViewer, implementado pelo Grupo de Bases de Dados e Imagens do ICMC - USP. O DicomViewer é um software para visualização e tratamento de imagens médicas, incorporando o suporte para imagens no formato DICOM e o formato proprietário GBDI. A interface padrão do DicomViewer pode ser vista na Figura 5.1.

Os recursos já existentes e os que foram agora implementados são descritos na Tabela 5.1.




Figura 5.1: Interface padrão do DicomViewer, software que serviu de base para a implementação do protótipo.

5.2.1 Formato de arquivos

Na maioria dos sistemas que processam imagens, o último nível é, quase sempre, a matriz de *pixels*. Essa matriz possui tamanho $W \times H$ onde W é sua largura e H sua altura e o valor em uma determinada posição $V[i, j]$ com $i < W$ e $j < H$ determina a cor utilizada ou, no caso de imagens monocromáticas, a intensidade do nível de cinza. Tanto o formato GBDI quanto o formato DICOM utilizam a biblioteca em constante desenvolvimento pelo GBDI denominada DicomLib¹. Essa biblioteca possui diversos métodos que auxiliam na manipulação das imagens, além de incorporar o Histograma Métrico e a busca por similaridade.

A abordagem BIC utiliza imagens JPEG e como a DicomLib não tinha, originalmente, suporte para este formato, sua implementação fez-se necessária. Primeiramente foi realizada uma pesquisa a respeito do formato JPEG e, por se tratar de um técnica complexa, optou-se em utilizar bibliotecas prontas que dão suporte a esse formato.

¹Maiores detalhes sobre a DicomLib pode ser encontrada em <http://gbdi.icmc.usp.br/devhelp/docs/dicomlib/>.

Dicomviewer		
	Recursos já existentes	Novos recursos incorporado
Formato de arquivos	Abre arquivos DICOM e GBDI. Exporta em formato BMP	Abre arquivos JPEG. Salva nos formatos GBDI e JPEG.
Filtros e bordas	Mediana, <i>auto-levels</i> , <i>blend alpha composite</i> , encontrar borda	Alteração de brilho, recorte da área útil por arquivo.
Visualização	Histograma, Histograma Métrico, informações da imagem	Visualizar a imagem em seu tamanho original.
Opções	<i>Auto-levels</i> automático, <i>color mapping view</i>	Brilho automático, <i>thumbnails</i> .
LocalebPACS	-	Conversão <i>batch</i> em JPEG, processamento e arquivamento de características sob a abordagem do histograma tradicional e métrico, busca por similaridade.
BIC	-	Processamento e arquivamento de características sob a abordagem BIC, busca por similaridade.

Tabela 5.1: Tabela de comparação entre o DicomViewer e as incorporações realizadas.

5.2.2 Filtros e Bordas

As imagens médicas que foram adotadas para este estudo possuem a característica de serem predominantemente escuras. Assim, uma boa visualização não é realizada quando a imagem é visualizada com suas cores originais. Uma maneira de contornar essa deficiência é a utilização de filtros digitais. A função *Auto-Levels* realiza o que é conhecido como “*stretching*” no histograma de cores, ou seja, o menor valor de *pixel* da imagem é posicionado como sendo de valor 0 no histograma e o *pixel* de maior valor é posicionado como o de maior intensidade de branco (valor 255). Os *pixels* intermediários são alterados proporcionalmente, permitindo uma visualização da imagem com melhor contraste.

O filtro da mediana suaviza a imagem, resultando na aparência de que ela foi “borrada”. O *Blend/Alpha Composite* gera uma imagem a partir de duas podendo determinar percentualmente qual das imagens terá maior ou menor visibilidade. Além desses filtros há o incremento de brilho na imagem além de funções de recorte da imagem. A imagem é recortada para maximizar a busca, realizando a extração de características no retângulo (MBR -

minimum boundary box) da área útil da imagem. Alguns exemplos da utilização dos filtros presentes no DicomViewer são apresentados na Figura 5.2.




Figura 5.2: Exemplos de utilização dos filtros do DicomViewer. a)imagem original, b)após aplicação do filtro da mediana com fator 2, c)após processamento de auto-levels e d) com adição de 100 unidades de brilho.

5.2.3 Visualização e opções

Na entrada Visualização, o usuário pode ter acesso à visualização do Histograma Métrico e do histograma normalizado, além de poder visualizar as informações das imagens DICOM. Caso a imagem em questão não seja do tipo DICOM, uma mensagem de erro será retornada para o usuário. A função “visualizar tamanho original” é útil nas consultas em que são apresentados *thumbnails*². A utilização de *thumbnails* é muito útil na apresentação de resultados de busca já que não ocupa muito espaço em memória e a visualização fica mais adequada quando são apresentadas muitas imagens na tela.

Uma outra função importante no sistema é a “Opções” a qual se pode escolher previamente em que modo as imagens serão abertas. Essas opções incluem o *auto-levels* automático, brilho automático e o *color mapping view* que adiciona cores à imagem de acordo com sua luminosidade. Esse tipo de visualização é comumente observado em mapas de medição de temperatura, onde as temperaturas mais quentes são coloridas de cores fortes como o vermelho e temperaturas mais amenas com tom mais suaves como o azul.

²imagem minimizada, pequena, que representa uma maior com mais detalhes, imagem em forma de slides.

5.2.4 LocalcbPACS

A função LocalcbPACS é responsável pelo módulo de recuperação de imagens por conteúdo. Como foi visto no Capítulo 3, as imagens devem passar por um pré-processamento onde suas características são extraídas e armazenadas em um vetor de característica. A função “processar imagens” realiza esse trabalho. Quando o usuário a seleciona o sistema informa que o processamento das imagens pode demorar, evitando assim que, com a demora do processo, se pense que o sistema não está processando as imagens. O tempo gasto, em média, para processar cerca de 5000 imagens foi de 15 minutos. Esse tempo varia de acordo com o tamanho da imagem já que a extração do histograma necessita a leitura completa da imagem. Após o processamento, as informações são salvas em um arquivo binário contendo os nomes dos arquivos das imagens e seus respectivos histogramas. A escolha do histograma (métrico ou normalizado) é feita na hora de selecionar o formato do arquivo a ser salvo, portanto, existe um arquivo para cada tipo de histograma.

Por ter sido construído como um protótipo, o armazenamento foi feito de modo linear e a recuperação de imagens é realizada através de uma busca seqüencial. Como as informações depois de lidas no arquivo são armazenadas em memória, o seu processamento é rápido. Em um conjunto maior de imagens seria necessário utilizar outra maneira de armazenar os dados para realizar a consulta, isto é, uma estrutura de indexação agilizaria a consulta.

Após as imagens terem sido processadas, pode-se realizar a consulta por similaridade. Uma imagem deve ser aberta e estar ativa na tela do usuário. Esta imagem deverá ser a imagem objeto para a consulta. A função “Vizinhos mais próximos” lê o arquivo de dados e em seguida extrai os dados da imagem ativa, comparando-a com todas as outras gravadas no arquivo. Como pode ser observado, essa implementação não prevê um grande número de imagens na base de dados e serve simplesmente para a validação dos resultados esperados. O usuário pode escolher entre a visualização em *thumbnails* ou em tabela, que apresenta as imagens em ordem de similaridade e o valor da distância em relação à imagem de consulta. Uma consulta dos 16 vizinhos mais próximos utilizando o Histograma Métrico é apresentada na Figura 5.3.

Foi criado também um conversor em lote para imagens JPEG. Este conversor foi necessário para utilizar a abordagem BIC, como será descrito a seguir.




Figura 5.3: Consulta por similaridade no protótipo adicionado ao DicomViewer.

5.2.5 BIC

A abordagem BIC, como apresentada na seção 3.5.2 (página 37), foi implementada para realizar comparações com os resultados do Histograma Métrico. A implementação foi adaptada para imagens monocromáticas, já que essa abordagem foi proposta para imagens coloridas. A dificuldade de encontrar sistemas em que utilizem exclusivamente imagens em tons de cinza foi grande e, após análise de várias abordagens, optou-se para a BIC pois trazia resultados muito animadores.

Da mesma maneira que o processamento das imagens foi necessário no histograma normalizado e métrico, na BIC faz-se necessário também. O armazenamento das informações foi realizado em um arquivo binário e a busca seguiu o mesmo procedimento do Histograma Métrico. A grande vantagem da utilização do BIC foi a economia de espaço para armazenamento das informações em disco.

A abordagem BIC, por ser mais adequada ao tratamento de imagens heterogêneas e coloridas teve um desempenho muito limitado, trazendo resultados pouco satisfatórios em comparação com o Histograma Métrico [Campo and Traina, 2003], como será visto na pró-

xima seção.

5.3 O Histograma Métrico Adaptado

Os PACS são ambientes complexos, que recebem imagens de diversas modalidades e periféricos, armazenando-os e transmitindo-os entre clientes e servidores. A variedade de equipamentos, procedimentos e pessoal técnico que os manuseiam tornam o processo de aquisição de imagens uma das partes mais delicadas deste processo, pois dependendo de como a imagem foi adquirida ela se torna mais escura (menos brilho) ou mesmo saturada (brilho em demasia). Tais variações dificultam a comparação entre imagens. Logo, a calibração do dispositivo de tomografia bem como a precisão do equipamento podem trazer mudanças consideráveis na imagem final. Essas mudanças são, normalmente, variações no brilho e no contraste da imagem. Os principais sistemas de recuperação de imagens por conteúdo baseado em cor não suportam essas variações, não recuperando de maneira eficiente a mesma imagem que tenha sofrido variações de brilho e/ou contraste [Campo and Traina, 2003].

O Histograma Métrico original tem a característica de ser invariante às transformações geométricas (escala, rotação e translação), mas apesar de intrinsecamente ser invariante também a transformações de brilho, isso não havia sido efetivamente testado e avaliado. Nenhuma técnica na literatura trata de maneira eficiente a questão da variação de brilho, e este trabalho visa a preencher esta lacuna. A Figura 5.4 ilustra três imagens onde ocorre variação de brilho e contraste e seus respectivos histogramas. Essa invariância a transformações de brilho é muito importante, porque imagens de mesmo paciente e exame ao serem adquiridas em situações diferentes tendem a variar o brilho. Assim pesquisas diretas por histogramas convencionais não recuperariam tais imagens que são inerentemente muito semelhantes.

Como pode-se observar pela Figura 5.4, a variação de brilho em uma imagem afeta diretamente seu histograma. Além disso, verificou-se que a variação de contraste o altera trazendo lacunas entre seus *bins*. Isto ocorre quando é utilizada a técnica conhecida como esticamento ou “*stretching*” do histograma. Tal técnica identifica os maiores e menores valores da tonalidade de cinza e os posicionam em seus extremos, ou seja, o branco e o negro mais intenso. Os valores dos *pixels* intermediários são posicionados proporcionalmente aos seus extremos, através de uma simples regra de três. Como os valores resultantes são inteiros, lacunas de dados são formadas. Quando isso ocorre, a performance do Histograma Métrico fica seriamente comprometida pois essas lacunas tornam-se o valor de mínimo local, produzindo *buckets* a cada par de *bin*.

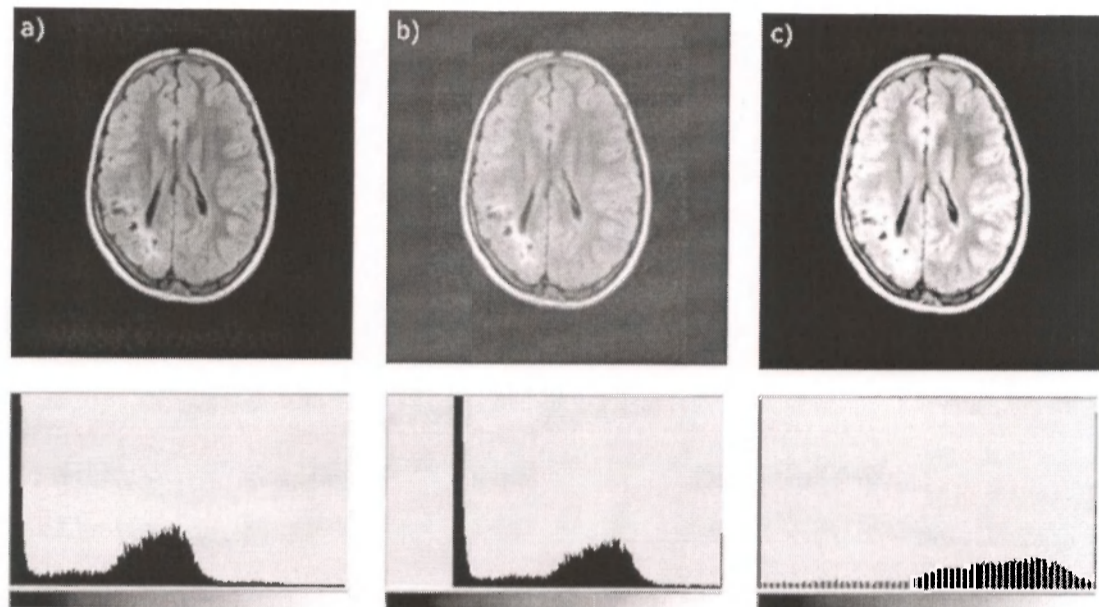


Figura 5.4: Imagem de exame de tomografia axial de cabeça humana. (a) imagem original, (b) imagem com o brilho alterado e (c) imagem com o contraste alterado.

Seria interessante se houvesse uma solução em que os dois problemas pudessem ser resolvidos de maneira simples e eficiente.

A implementação do Histograma Métrico foi alterada, tornando-a livre das variações lineares de brilho, atendendo à comparação de imagens adquiridas por equipamentos diferentes. O procedimento consiste em eliminar *bins* onde seus valores sejam desprezíveis sem causar prejuízo à curva do histograma. Esta eliminação de informação deve ser feita nos *bins* iniciais e finais do histograma analisado. Além disso, é possível realizar a eliminação no meio do histograma, tornando-o assim inerente a variações de contraste.

Como o Histograma Métrico é gerado a partir do histograma normalizado, na construção do mesmo, estipula-se um valor limite (V_L) e qualquer valor abaixo deste é ignorado. Assim, imagens com variações de brilho mas com a mesma distribuição de cores, são consideradas semelhantes. A escolha do V_L é de fundamental importância para o bom funcionamento do sistema. Esse valor de tolerância pode ser estipulado de acordo com as características do equipamento em que foi realizado o exame ou obtendo-se uma média dos valores não significativos de cores dos histogramas das imagens. Assim, após o processo de construção, o HM resultante é o mesmo de um sem a variação de brilho. A Figura 5.5 exemplifica um histograma onde ocorre variação de brilho com um V_L apropriado e o histograma resultante do processo. Nos experimentos realizados, foi utilizado um V_L de 0,0005 que corresponde a 0,05% do valor máximo que um *bin* pode assumir.

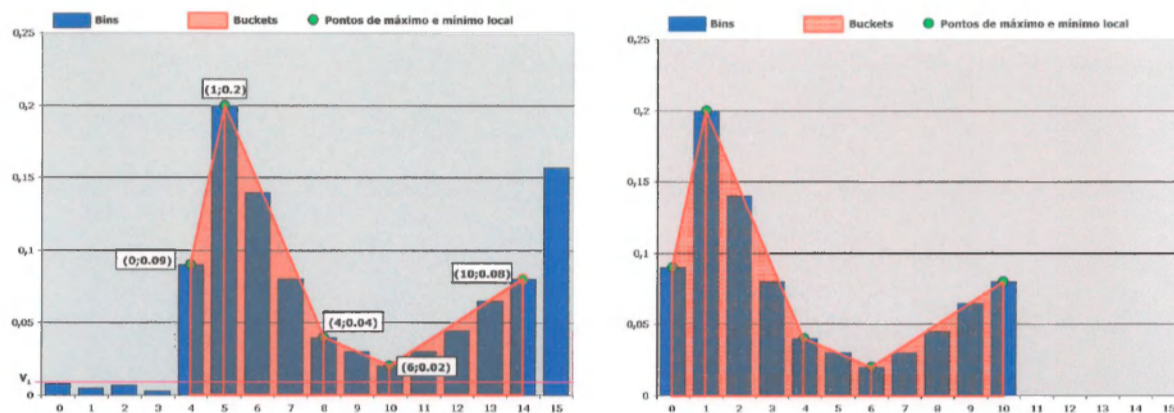


Figura 5.5: Ilustração de como é realizado a invariância ao brilho no Histograma Métrico.

Em se tratando de variações de contraste, a abordagem presente só funciona caso a sua alteração tenha sido feita em uma etapa posterior à aquisição da imagem e através do *stretching*. Assim como na invariância a brilho, é necessário estipular um valor limite (V_L). A invariância a contraste é ilustrada na Figura 5.6.

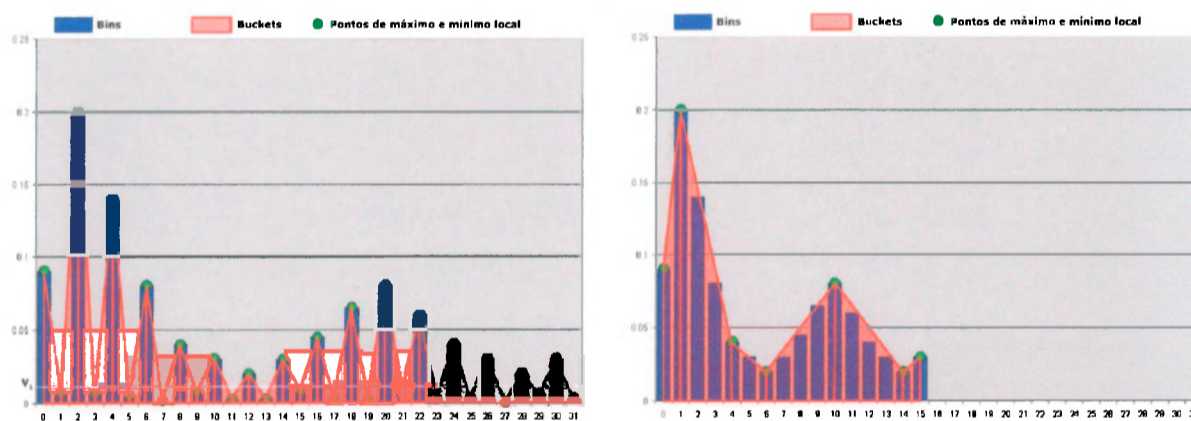


Figura 5.6: Histograma com seu contraste alterado através do *stretching* simples e seu Histograma Métrico correspondente. A utilização do limite V_L elimina os *bins* irrelevantes, recuperando sua curva original (à direita).

Imagens similares com seu contraste alterado possuem predominantemente o mesmo formato da curva do histograma. Para o reconhecimento da forma da curva e armazenamento deste como vetor de característica outras técnicas são necessárias e não foram abordadas neste trabalho.

Uma abordagem apresentada em [Keogh, 2002], utiliza uma distância denominada de “*Warp Distance*” a qual foi implementada no protótipo. Tal abordagem utiliza uma aproximação entre duas curvas, distorcendo a área formada por elas e, assim, realizando uma

medição preservando a curva do objeto a ser medido. A Figura 5.7 ilustra duas curvas onde ocorre a “distorção” de áreas para melhor desempenho da distância. Na proposta original a distância apresentou-se eficiente para séries temporais e, potencialmente, é útil para a medição de similaridade entre histogramas. Infelizmente os resultados preliminares não foram satisfatórios, trazendo como resultados das consultas elementos bem distintos do procurado. Esta abordagem faz parte do estudo de um aluno de doutorado do GBDI/ICMC-USP e foi testada e implementada no protótipo descrito na seção 5.2.




Figura 5.7: Ilustração do funcionamento da *Warp Distance* onde ocorre a “distorção” de área permitindo um melhor cálculo de similaridade entre curvas.

Resultados preliminares

Foram realizados experimentos preliminares para avaliar a eficácia das consultas por similaridade utilizando o Histograma Métrico modificado para suporte a variações de brilho. Assim, analisa-se o número de imagens corretas retornadas pelo processo automático de busca. Para uma boa avaliação de busca, é necessário que o especialista agrupe as imagens em conjuntos, mantendo as que são similares entre si. No entanto, pode-se observar sua similaridade em decorrência da forma e classificação das mesmas como tomografias de cabeça, tórax e membros.

Os experimentos efetuados utilizaram um conjunto de 8.848 imagens médicas de diferentes estruturas corpóreas, cedidas pelo Hospital das Clínicas de Ribeirão Preto da Universidade de São Paulo. Esse conjunto é constituído por dois subconjuntos: 4.424 imagens originais e 4.424 imagens com brilho alterado, que correspondem às imagens originais do primeiro subconjunto. Foram buscadas as 32 imagens mais similares, utilizando o Histograma Métrico com invariância a brilho e a abordagem BIC.

Por ser mais adequada ao tratamento de imagens heterogêneas e coloridas, a abordagem BIC teve um desempenho muito limitado, trazendo resultados pouco satisfatórios em comparação com o Histograma Métrico. A Figura 5.8 mostra um exemplo de consulta utilizando tal abordagem.




Figura 5.8: Consulta *32-Nearest Neighbors* utilizando a abordagem BIC.

O Histograma Métrico recuperou as 32 imagens mais similares à imagem de consulta e através da Figura 5.9 pode-se comparar a eficácia das abordagens. As imagens, independente do grau de alteração de seu brilho foram recuperadas sem qualquer problema, pelo Histograma Métrico.




Figura 5.9: Consulta *32-Nearest Neighbors* utilizando a abordagem do Histograma Métrico.

5.4 O Sistema de Recuperação de Imagens do Hospital das Clínicas de Ribeirão Preto

O Sistema de Recuperação de Imagens Similares - SRIS-HC foi desenvolvido com a finalidade de demonstrar a viabilidade da técnica de recuperação de imagens por conteúdo no Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto da Universidade de São Paulo (HCFMRP/USP). Além disso, tal funcionalidade é um recurso adicional de um Sistema PACS, uma vez que os sistemas PACS tradicionais não suportam ainda esse recurso de grande interesse que é a busca de imagens similares e a recuperação por conteúdo.

O projeto original do SRIS foi desenvolvido em [Rosa, 2002] e está sendo continuado por este presente trabalho. As funcionalidades implementadas no protótipo foram adaptadas para este sistema, deixando-o mais robusto nas consultas por similaridade.

O SRIS-HC foi desenvolvido como uma extensão do Sistema de Informação em Radiologia (RIS) do Serviço de Radiodiagnóstico do HCFMRP/USP - o Sistema de Laudo Eletrônico. Assim, as funcionalidades do sistema original foram mantidas totalmente, inclusive o padrão dos módulos de consultas do Sistema de Laudo Eletrônico, que é a porta para a integração com os demais Sistemas de Informação Hospitalar do hospital, e com o mini-PACS que vem sendo desenvolvido, conforme ilustra a Figura 5.10.




Figura 5.10: Integração SRIS-HC com RIS, HIS e mini-PACS do HCFMRP/USP.

Devido à integração do SRIS-HC com o Sistema de Laudo, é possível fazer consultas por similaridade, visualizando além das imagens resultantes da consulta, todas as informações relativas ao exame feito (tais como data, local de realização, clínica, região, modalidade,

equipamento e informações do paciente), inclusive o laudo médico do exame. O SRIS-HC permite ainda consultar um exame e visualizar todas as imagens do exame em pequenos *thumbnails*.

O sistema deverá aumentar a frequência com que os médicos farão uso de pesquisa de imagens de outros estudos dos pacientes com o intuito de auxiliar na interpretação do estudo corrente. Esse aumento na utilização desses recursos deve-se ao fato de que, disponibilizando o acesso ao sistema através das estações de trabalho localizadas em qualquer local do hospital, os médicos poderão pesquisar as imagens sem terem que se dirigir ao Serviço de Radiodiagnóstico para solicitar as imagens que desejam visualizar, ocorrendo uma redução do esforço necessário para se fazer busca de imagens.

Para tanto, é necessário que a recuperação e disponibilização das imagens consultadas seja rápida e eficiente, sendo necessário o uso de estruturas de indexação que possibilitem a indexação e recuperação das imagens de forma otimizada. Essa otimização é conseguida através do armazenamento de todas as informações relativas à imagem como seus vetores de características e a própria imagem. As características e as imagens são armazenadas utilizando seqüência de bytes, armazenando-as na base de dados no tipo de dados BLOB (*Binary Large Object*).

As imagens são indexadas e recuperadas através de características extraídas das mesmas. O SRIS-HC suporta atualmente duas técnicas de extração de características de imagens baseadas na distribuição dos níveis de cinza: o histograma tradicional e o Histograma Métrico. As características são extraídas e armazenadas na base de dados juntamente com as imagens para que possam ser armazenadas na estrutura métrica Slim-tree. É através da Slim-tree que essas características são indexadas e consultadas.

O processo global do SRIS-HC consistiu em armazenar as imagens na base de dados, relacionando-as com o exame do Sistema de Laudo Eletrônico através da chave do exame contida no arquivo DICOM das imagens (conforme ilustra a Figura 5.11). Estando as imagens armazenadas na base, relacionadas com os exames radiológicos, é possível fazer consultas baseadas no conteúdo das imagens exibindo as imagens resultantes da pesquisa juntamente com todas as informações relativas ao exame que gerou cada imagem, inclusive o laudo médico do exame. Como atualmente o Sistema de Laudo Eletrônico abrange somente as informações textuais do exame, O SRIS-HC poderá ser adotado como uma extensão do mesmo, uma vez que irá permitir uma consulta mais completa dos exames radiológicos, exibindo além das informações textuais, todas as imagens pertencentes ao exame.

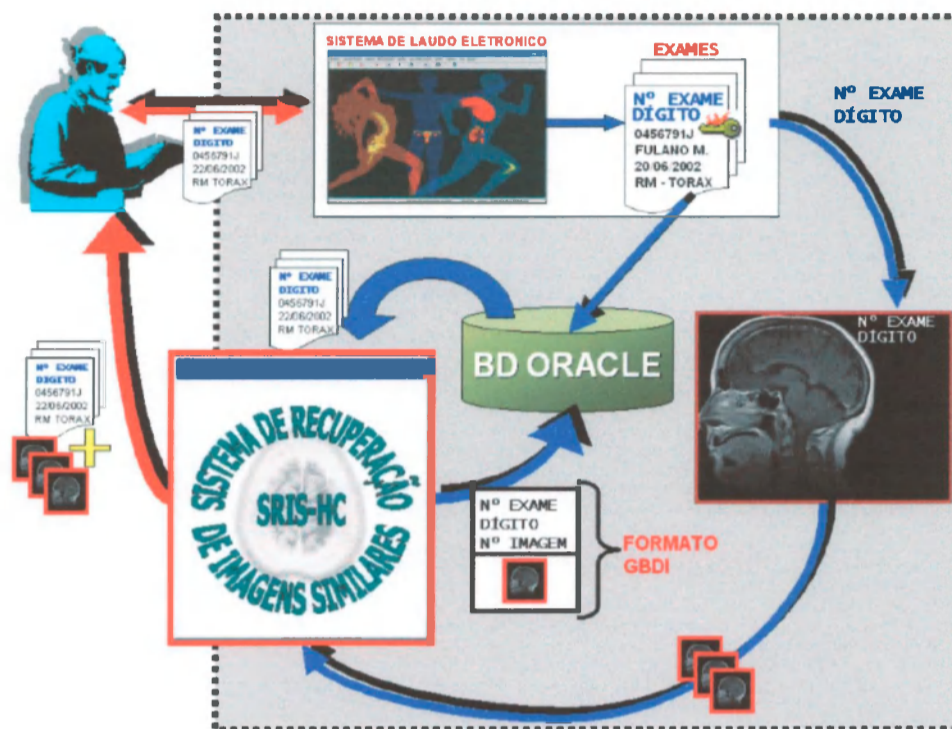


Figura 5.11: Processo global do Sistema de Recuperação de Imagens Similares - SRIS-HC.

5.4.1 Arquitetura do SRIS-HC

O SRIS-HC é composto dos seguintes módulos principais [Rosa, 2002]:

1. Módulo de Armazenamento das Imagens e Características Extraídas;
2. Módulo de Extração e Armazenamento de Características das Imagens Posterior ao Armazenamento;
3. Módulo de Montagem da Árvore Slim-tree;
4. Módulo de Consulta de Imagens Similares (núcleo do sistema);
5. Módulo de Consulta de Exames dos Pacientes e Respektivas Imagens e Laudos Médicos;
6. Módulo de Visualização de Logs de Armazenamento;
7. Módulo de Acesso ao Sistema;

A Figura 5.12 permite uma visão geral dos módulos que compõem o SRIS-HC.

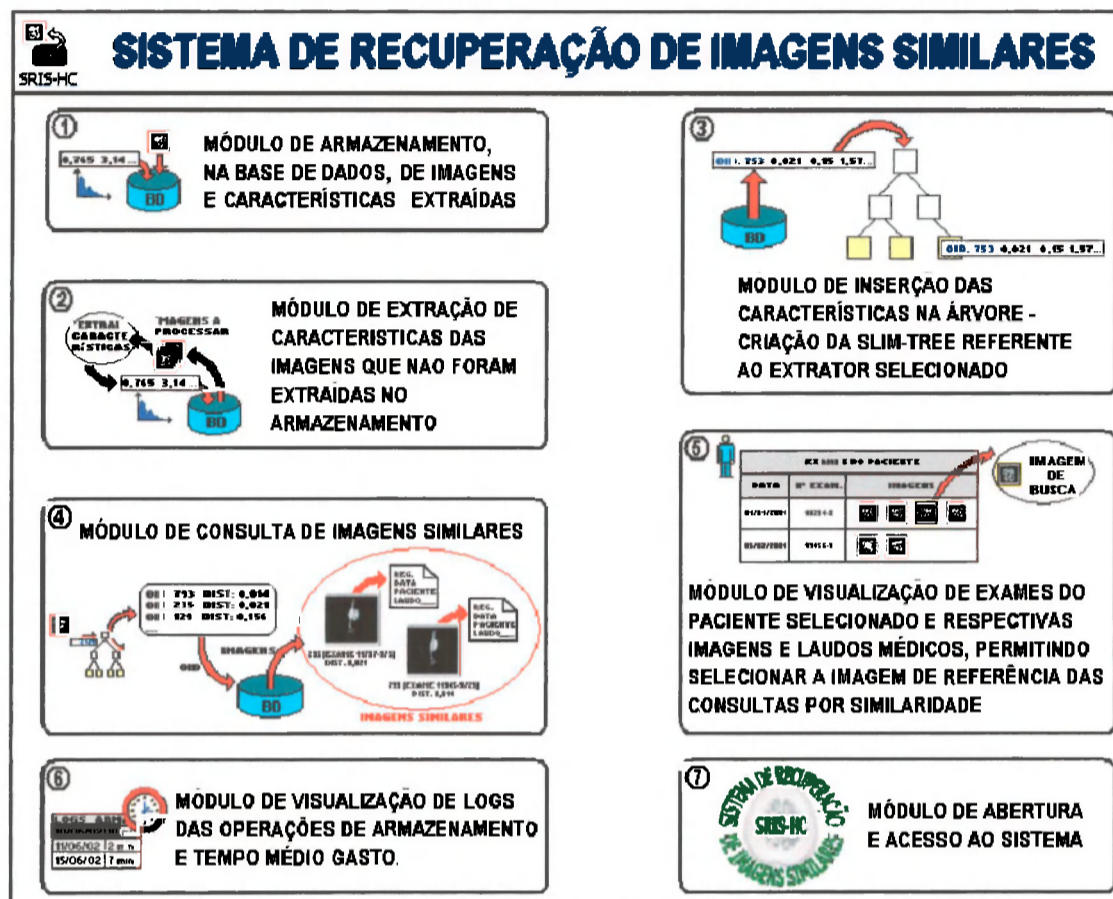


Figura 5.12: Arquitetura do SRIS-HC.

Os módulos do SRIS serão descritos a seguir. As funcionalidades que foram incorporadas ao sistema serão descritas em seus respectivos módulos. Um detalhamento maior pode ser obtido em [Rosa, 2002].

Armazenamento das Imagens e Características Extraídas

As imagens são armazenadas na base de dados e processadas, extraindo as suas características. Estas são também armazenadas para consultas posteriores. O armazenamento pode ser feito de diferentes maneiras: por uma base de dados já pronta pelo sistema de laudos ou por arquivos DICOM.

Este módulo foi alterado para dar suporte a imagens GBDI. Como as imagens DICOM possui *tags* nas quais são armazenadas informações relativas ao exame, a inserção na base de dados é feita de maneira automática. Porém, o formato GBDI armazena simplesmente o mapa de *pixels* da imagem e informações relativas exclusivamente à imagem, não podendo,

portanto, realizar sua inserção automática. A alteração do módulo consistiu em adicionar um item permitindo assim que as imagens fossem adicionadas em exames nos quais não haviam imagens cadastradas. Esse procedimento foi realizado apenas para a validação do sistema de recuperação por similaridade. As imagens eram agrupadas aleatoriamente em conjuntos de 40 imagens por exame. Como haviam dois tipos de imagens (as originais e as com brilho sinteticamente alterado), cada exame possui 80 imagens armazenadas. A Figura 5.13 apresenta a interface que realiza o armazenamento.

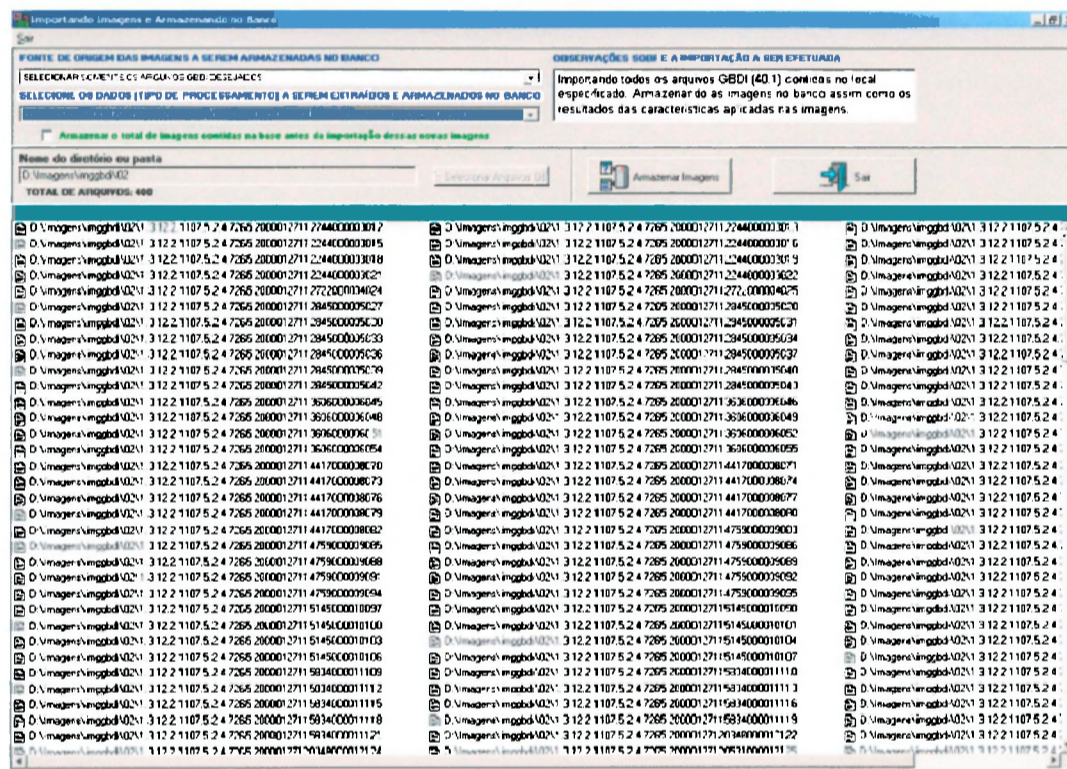


Figura 5.13: Interface em que as imagens GBDI são inseridas para validação.

Antes de iniciar o armazenamento da primeira imagem, é gerado um registro de *log* (o *log* de armazenamento é inicializado), para que o número desse registro seja armazenado junto com as imagens e as características. Este *log* conterá inclusive uma breve descrição da operação de armazenamento, fornecida pelo usuário, conforme possibilita o módulo de armazenamento de imagens e características.

Extração e Armazenamento de Características das Imagens Posterior ao Armazenamento

Neste módulo, é possível selecionar o extrator a ser aplicado nas imagens ainda não processadas (extraíndo as características) ou selecionar todos os extratores ativos. Após esta operação, seleciona-se todas as imagens existentes na base que não possuem características extraídas através dos extratores ativos selecionados, retornando um conjunto de imagens a ser processado. A partir deste conjunto serão obtidas as características das imagens referentes a cada extrator e armazenadas na base. Além disso, essa operação irá gerar um *log* de armazenamento contendo a data e hora de início e fim da armazenagem. É possível também saber quais características ou imagens foram envolvidas nesse processo.

A alteração do Histograma Métrico foi realizada na biblioteca DicomLib. Este módulo a utiliza para realizar a extração de características e não foi necessária nenhuma modificação neste. Como as imagens armazenadas anteriormente no banco já haviam passado pelo processo de extração de característica, elas não sofreram a alteração proposta.

Montagem da Árvore Slim-tree

Antes de iniciar alguma consulta, a Slim-tree deve ser montada. É necessário escolher por qual característica ela será estruturada e então é iniciada sua construção. O tempo médio de inserção é de, aproximadamente, 50 segundos para 18.000 imagens. Após a inserção, a árvore estará pronta para ser utilizada e este processo não será mais necessário durante a sessão de consultas, inclusive o acesso a este módulo de montagem da árvore é bloqueado. A menos que o usuário saia do sistema e retorne novamente, essa rotina não será mais executada.

Consulta de Imagens Similares (núcleo do sistema)

Este módulo é considerado o núcleo do SRIS-HC, pois engloba todos os demais módulos (que foram desenvolvidos para possibilitar a execução de consultas por similaridade). É através desse módulo que as consultas por similaridade (*k-Nearest Neighbor Query* ou *Range Query*) são executadas e as imagens semelhantes à imagem de referência são recuperadas.

Para executar uma consulta por similaridade é necessário fornecer a imagem de referência (ou de busca) a ser utilizada. Através da imagem de busca, executa-se uma busca por imagens similares (em Histogramas Métricos ou tradicionais, conforme extrator selecionado) à imagem de referência, de acordo com os critérios de consulta fornecidos (tipo de consulta, número de imagens similares, ou faixa de similaridade). A imagem de referência das consultas

pode estar armazenada no banco (em formato GBDI) ou no computador do usuário (que obrigatoriamente deveria ser no padrão DICOM). O sistema foi adicionado de alguns recursos que permitem realizar consultas através de arquivos nos formatos GBDI e JPEG, além do DICOM que já era utilizado. Essa funcionalidade é bastante útil em vista de que o Grupo de Bases de Dados e de Imagens utiliza o formato GBDI com frequência e o formato JPEG é um dos mais difundidos para armazenamento de imagens.

Após selecionar uma imagem de referência, o sistema verifica se a mesma possui a característica previamente selecionada na montagem da Slim-tree, já extraída e armazenada na base. Se a característica já estiver na base, a mesma será convertida em um objeto de busca da Slim-tree. Caso contrário, a imagem passará pelo processo de extração dessa característica, sendo então armazenado na base o vetor de características resultante (para evitar que a mesma imagem passe por esse processo caso seja selecionada novamente). Após o armazenamento da característica extraída, esta será convertida no objeto de busca da Slim-tree. A partir daí, o processo de consulta é único, de acordo com os critérios de pesquisa fornecidos pelo usuário (tipo da consulta, número de imagens desejadas, ou faixa de similaridade a que devam se encontrar as imagens resultantes).

Consulta de Exames dos Pacientes e Respectivas Imagens e Laudos Médicos

O módulo de consulta de exames de pacientes e respectivas imagens e laudos médicos foi desenvolvido, originalmente, mantendo o padrão do módulo de consulta de exames de pacientes do Sistema de Laudo Eletrônico, com o recurso adicional de visualização de todas as imagens dos exames, em miniaturas, com a possibilidade de visualizar uma imagem desejada em seu tamanho original [Rosa, 2002].

A finalidade do módulo foi permitir ao usuário selecionar uma imagem de um exame de um paciente para servir como imagem de referência das consultas por similaridade, além de permitir consultar exames de pacientes com as imagens associadas.

Se o exame possuir imagens armazenadas na base (uma vez que é uma base de teste e que nem todos os exames possuem imagens associadas), basta dar um duplo clique no exame desejado para visualizar as imagens em miniaturas. Caso o usuário queira visualizar a imagem em seu tamanho natural basta dar um duplo clique sobre a miniatura.

Para cada exame selecionado, efetua-se uma busca na base de dados de todas as imagens, montando então as miniaturas a serem exibidas. Uma vez montadas as miniaturas do exame, pode-se salvá-las em um arquivo, de tal forma que a próxima vez que o mesmo exame for selecionado, não haverá necessidade de montar miniaturas das imagens, que é um processo

lento, uma vez que as imagens do exame serão sempre as mesmas. As Figuras 5.14 e 5.15 apresentam o laudo e as imagens proveniente de um exame.

Nº Exame	Data	Realizado	Exame	Região	Procedimento	Definição	Tipo	Total Imagens
88253	3/19/2018	Realizado	RESSONANCIA MAGNETICA	MÃO	EX70201	35470201	Distúrbio	0
25495	3/19/2018	Realizado	RESSONANCIA MAGNETICA	MÃO	EX70201	35470201	Mão Lesão	0
25229	2/24/2018 08:42:42	Realizado	FLUOROGRAFIA SAMPLES	MÃO	EX70201	25470201	Distúrbio	0
13229	1/12/2018 0 3:47	Realizado	ULTRA SONOGRAFIA	MÃO	EX70201	760200	Distúrbio	0

LAUDO MÉDICO DO EXAME ACIMA REFERENCIADO

Descrição do Laudo
 Estruturas ósseas regionais: completude de linha preservada.
 Estruturas vasculares nervosas do peso braquial: forma, orientação e intensidade de sinal normais.
 Ausência de lesões expansivas da região citocoronária.
 Não há alteração de aspecto normal.

Conclusão do Laudo
 Lesão normal.

LAODEPIN BRUNO HENRIQUE FILAN
 R: Médico
 DR. G. G. D. M. A. C. D. L. N. G. A. H. R.

de um clique clique sobre o exame para visualizar todas as imagens

Figura 5.14: Tela de consulta ao laudos de um paciente e suas respectivas informações.

Visualização de Logs de Armazenamento

O módulo de Visualização de Logs de Armazenamento foi desenvolvido para que possa fornecer uma estimativa do tempo necessário para se armazenar as imagens, as características extraídas ou ambas.

Nesse módulo é possível visualizar também o total de imagens envolvidas no processo, seja nos processos de armazenamento das imagens (armazenamento parcial ou total) ou no processo de extração das características posterior ao armazenamento. Além disso, uma outra informação adicional é o tempo médio gasto no processo todo referente ao log.

A Figura 5.16 ilustra todas as informações contidas no módulo de visualização de logs. Note que no final da tela pode-se visualizar a descrição do log selecionado (corrente), descrição essa que o usuário fornece antes do armazenamento das imagens, ou que o sistema gera na tela de extração das características.

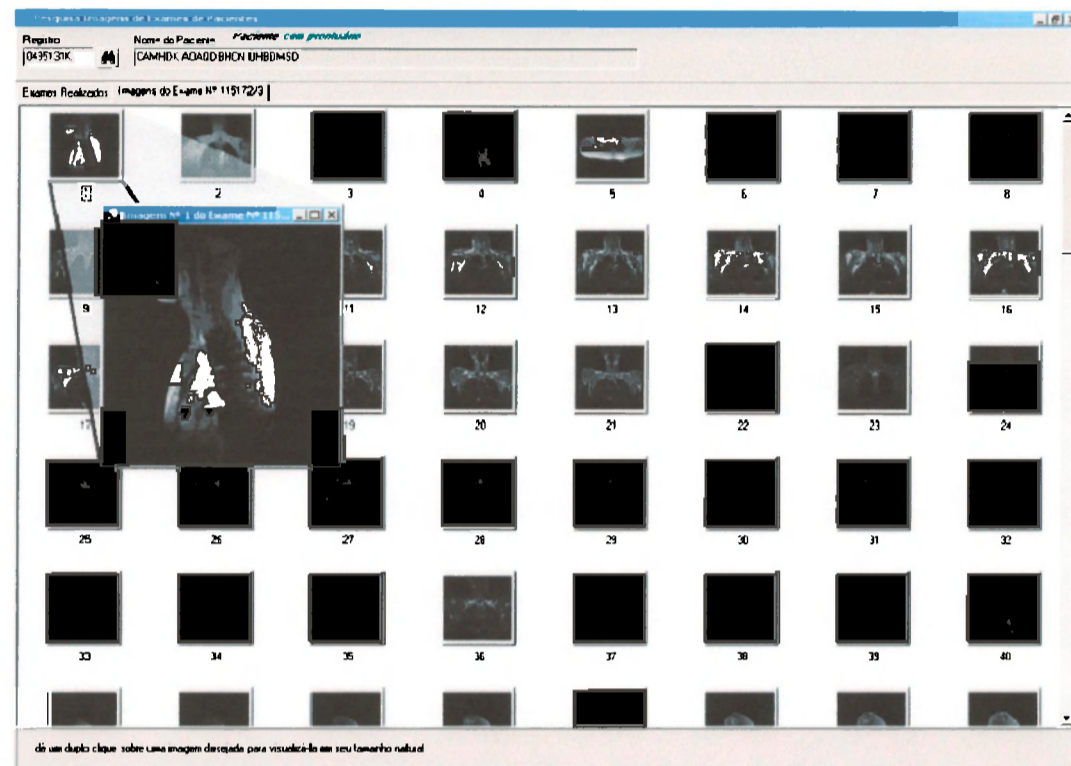


Figura 5.15: Tela das imagens em miniatura (*thumbnails*) do exame e a primeira imagem em tamanho natural.

Os processos de armazenamento nos quais ocorrem erros antes da finalização do *log*, não possuem na Figura a data e hora do término do processo. Além disso, em sua inicialização armazena-se o total de imagens que serão processadas e, na finalização, o total que foi realmente processado. Sendo assim, caso dê erro antes do término da operação, essa informação estará desatualizada [Rosa, 2002].

Acesso ao Sistema

Referente às políticas de segurança do sistema, o SRIS-HC foi desenvolvido em conformidade com os demais sistemas do HCFMRP. É necessário que o usuário possua um nome-de-usuário e senha, adquirido junto ao Centro de Informações e Análises do HCFMRP, para estar utilizando os demais sistemas existentes no Hospital das Clínicas [Rosa, 2002].

Este módulo foi modificado para ser possível a ligação de diversas bases de dados. Para isso foi adicionado um campo onde o usuário deverá escolher a base que desejará usar.

O módulo de acesso ao sistema (Figura 5.17) é a tela de conexão do usuário com a base de dados, onde são solicitadas as informações para validar o acesso a tela principal do SRIS-HC.

Visualiza logs de armazenamento de imagens e características processadas

MOSTRAR TODOS OS LOGS DE ARMAZENAMENTO MOSTRAR TODOS OS LOGS A PARTIR DO DIA: 12/2/2004 Pesquisar

Nº LOG	INÍCIO	TÉRMINO	TIPO DE OPERAÇÃO	TEMPO GASTO	TOTAL IMAGENS	MÉDIA (SEG) / IMAGEM
86	27/7/2002 17:27:29	27/7/2002 17:30:09	SOMENTE CARACTERÍSTICAS	2 m 40 s	0	0.00
87	27/7/2002 17:38:33		SOMENTE CARACTERÍSTICAS		10390	0.00
92	4/8/2002 13:19:44	4/8/2002 14:43:56	SOMENTE CARACTERÍSTICAS	1 h 24 m 12 s	4631	1.09
93	4/8/2002 14:47:45	4/8/2002 15:53:25	SOMENTE CARACTERÍSTICAS	1 h 5 m 41 s	2973	1.33
97	4/8/2002 16:35:45		SOMENTE CARACTERÍSTICAS		2786	0.00
98	4/8/2002 16:41:23	4/8/2002 17:30:42	SOMENTE CARACTERÍSTICAS	49 m 20 s	2786	1.06
100	14/1/2004 23:13:45	14/1/2004 23:16:05	IMAGENS E CARACTERÍSTICAS	2 m 20 s	800	0.18
101	14/1/2004 23:19:47	14/1/2004 23:22:41	IMAGENS E CARACTERÍSTICAS	2 m 55 s	800	0.22
102	14/1/2004 23:24:53	14/1/2004 23:27:16	IMAGENS E CARACTERÍSTICAS	2 m 23 s	800	0.18
103	14/1/2004 23:27:38	14/1/2004 23:29:53	IMAGENS E CARACTERÍSTICAS	2 m 16 s	800	0.17
104	14/1/2004 23:30:44	14/1/2004 23:32:31	IMAGENS E CARACTERÍSTICAS	1 m 48 s	800	0.14
105	14/1/2004 23:33:27	14/1/2004 23:35:43	IMAGENS E CARACTERÍSTICAS	2 m 16 s	800	0.17
106	14/1/2004 23:36:39	14/1/2004 23:38:21	IMAGENS E CARACTERÍSTICAS	1 m 43 s	800	0.13
107	14/1/2004 23:39:26	14/1/2004 23:41:11	IMAGENS E CARACTERÍSTICAS	1 m 46 s	800	0.13
108	14/1/2004 23:42:47	14/1/2004 23:44:44	IMAGENS E CARACTERÍSTICAS	1 m 58 s	800	0.15
109	14/1/2004 23:45:39	14/1/2004 23:47:53	IMAGENS E CARACTERÍSTICAS	2 m 15 s	800	0.17

DESCRIÇÃO DO LOG ACIMA SELECIONADO

Importando todos os arquivos GBDI (40.1) contidos no local especificado

Figura 5.16: Tela da apresentação dos logs do banco de imagens.

SRIS-HC - Sistema de Recuperação de Imagens Similares



Base a ser utilizada:

USUÁRIO :

SENHA :

Figura 5.17: Tela de conexão do usuário com a base de dados e acesso ao SRIS-HC.

5.5 Resultados

A seguir serão apresentados os resultados obtidos com a implementação final no SRIS-HC. A abordagem BIC não foi adicionada ao sistema, tendo em vista que seus resultados não foram satisfatórios, como ressaltado na seção 5.2.5.

Os experimentos foram realizados em um conjunto de 18.874 imagens, sendo que 10.390 já estavam na base de dados original e 8.484 foram inseridas para a realização de testes e experimentos. Deste último conjunto de imagens, metade delas (4242) tiveram seu brilho alterado linearmente em 100 unidades de brilho. O conjunto inserido para experimentos teve um diferencial qualitativo muito grande em relação ao armazenado na base. As imagens na base foram armazenadas integralmente, com grande parte da imagem sendo o fundo negro. As inseridas, tiveram o recorte de sua área útil (*MBB - Minimum Boundary Box*), melhorando a qualidade das informações de cores. Um exemplo do que foi armazenado pode ser observado na Figura 5.18.




Figura 5.18: Imagem original de crânio (esquerda) e a mesma com o recorte do MBB (*Minimum Boundary Box*).

A montagem da Slim-tree com esse total de imagens foi de 44 segundos. Um tempo considerado tolerável, já que, com a adoção da árvore, as consultas são realizadas muito mais rapidamente. O computador utilizado é apresentado na Tabela 5.2.

Os experimentos foram divididos em 4 casos. Em todos os casos utilizou-se uma imagem de referência aleatória e realizou-se a consulta no sistema através do histograma normalizado e métrico adaptado. Tanto a consulta aos vizinhos mais próximos quanto a consulta por abrangência foram realizadas. Todas as imagens de referência apresentadas estão em seu tamanho original.

Característica do computador utilizado nos experimentos	
Processador	Intel Pentium 4A, 2433 MHz
Sistema Operacional	Microsoft Windows 2000 Professional
Memória do Sistema	1024 MB (DDR SDRAM)
Adaptador gráfico	NVIDIA RIVA TNT2 Model 64/Model 64 Pro (32 MB)
Disco rígido	MAXTOR 4K080H4 (80 GB, 5400 RPM, Ultra-ATA/100)
Base de dados	Oracle9i Database Release 2 (9.2) for Windows
Compilador	Borland C++ Builder Enterprise Suite Versão 5.0

Tabela 5.2: Configuração do computador utilizado para os experimentos.




Figura 5.19: Imagem de referência para o primeiro caso.

Uma consulta aos 48 vizinhos mais próximos foi realizada. A imagem de referência foi a de um crânio, escolhida aleatoriamente (Figura 5.19). O tempo gasto para realizar as consultas nunca ultrapassou um segundo, mas o tempo de construção das janelas dos resultados varia de acordo com o número de imagens (*thumbnails*) que será observado. As imagens de referências foram inseridas para a consulta através da opção “Selecionar imagem na pasta do computador” e estavam no formato GBDI. Consultas através do formato DICOM e JPEG também são permitidas, mas como a extração de característica da imagem de referência possui um custo computacional ínfimo tendo o mesmo desempenho, optou-se por utilizar as imagens GBDI.

O resultado da consulta pode ser observado através da Figura 5.20, onde foi utilizado uma consulta aos 40 vizinhos mais próximos através do histograma normalizado. As imagens recuperadas são próximas à de consulta, porém ela está susceptível a variações de brilho. Isso pode ser observado nos resultados pois nenhuma das imagens com o brilho alterado na base estava contida no conjunto do resultado. Uma consulta por abrangência também foi realizada com raio de 0.3 unidades e seu resultado pode ser observado através da Figura 5.21.

O Histograma Métrico adaptado produziu resultados bem distintos do histograma normalizado. A consulta foi realizada com os mesmos parâmetros do anterior. A variação de brilho não trouxe problemas na recuperação de imagens, como pode ser observado nas Figuras 5.22 e 5.23.

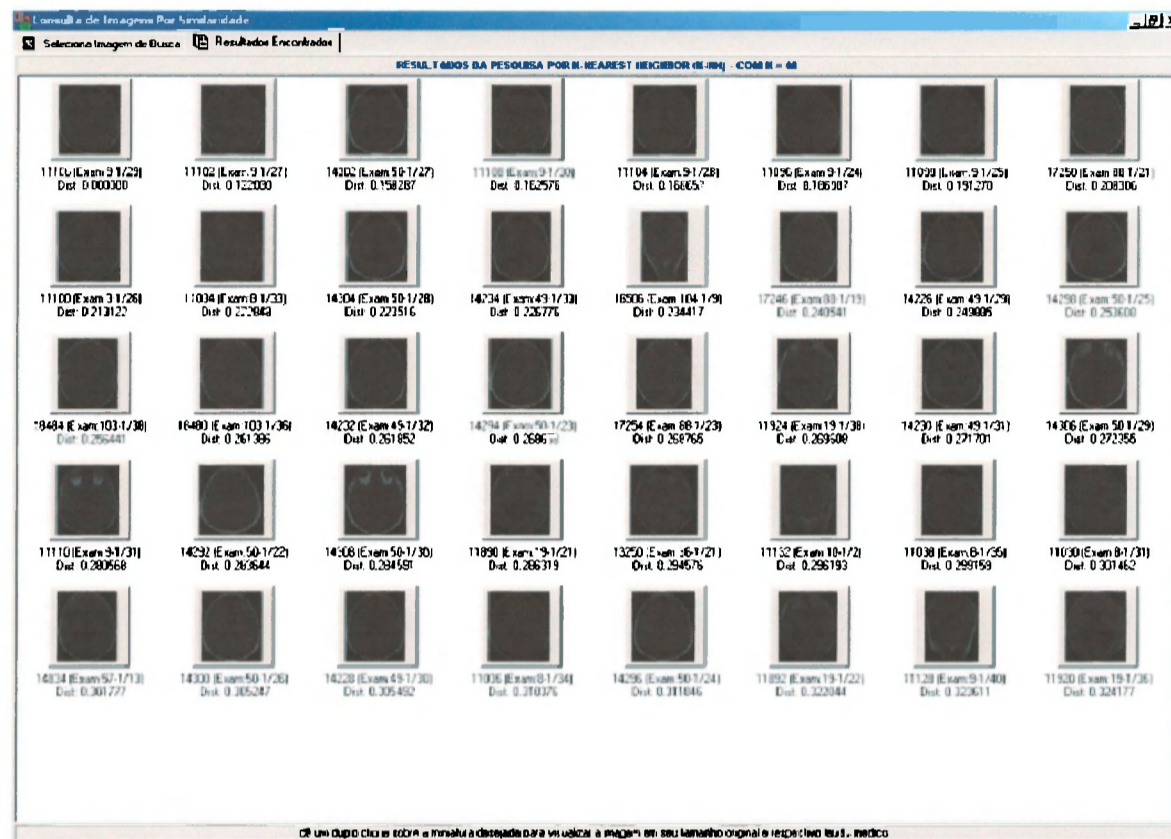


Figura 5.20: Resultado da consulta aos 40 vizinhos mais próximos utilizando o histograma normalizado.

Um resumo dos testes realizados é apresentado na Tabela 5.5. As imagens dos resultados obtidos não constam neste capítulo (caso 2, 3 e 4) mas estão no Apêndice A.

5.6 Considerações Finais

Este Capítulo apresentou o trabalho desenvolvido e as modificações efetuadas no SRIS-HC, além da evolução do sistema, desde o seu protótipo até a implementação final.

Descreveu-se como o Histograma Métrico adaptado pode ser invariante às mudanças de brilho, tornando-o uma abordagem compacta, e eficiente para a recuperação de imagens médicas que são obtidas por processos distintos de aquisição. O Histograma Métrico utiliza *buckets* de tamanho variável, diferentemente das abordagens tradicionais que restringem a quantidade de *bins*. Além disso utiliza uma métrica baseada na diferença de áreas entre histogramas normalizados.

O principal componente para aprimorar o histograma e deixá-lo invariante ao brilho é

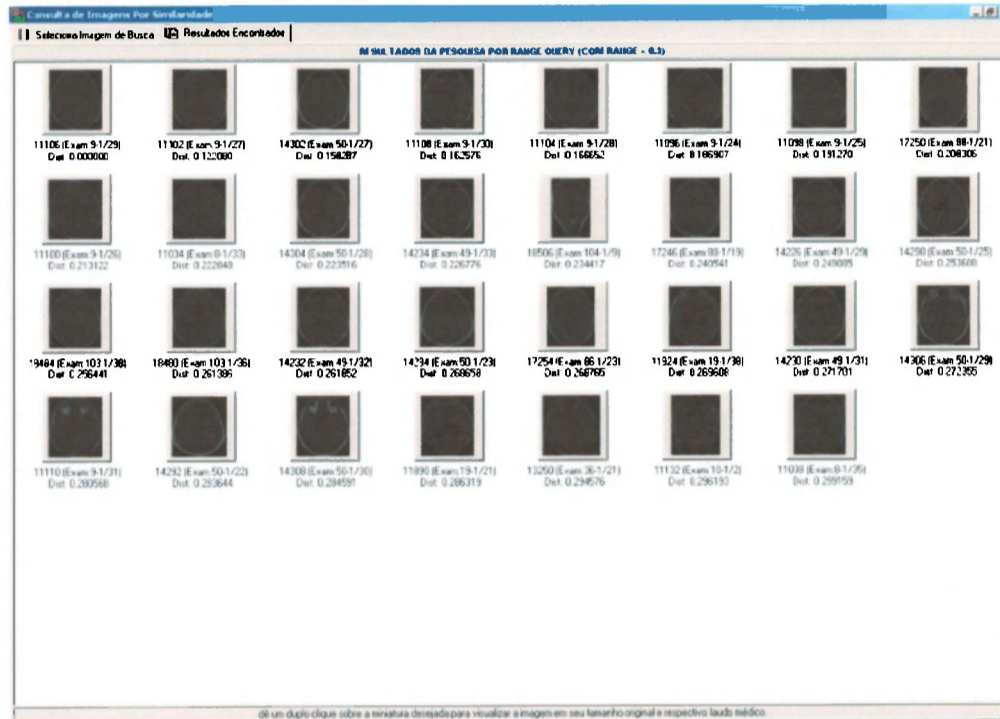


Figura 5.21: Consulta por abrangência com raio de 0.3 utilizando o histograma normalizado.

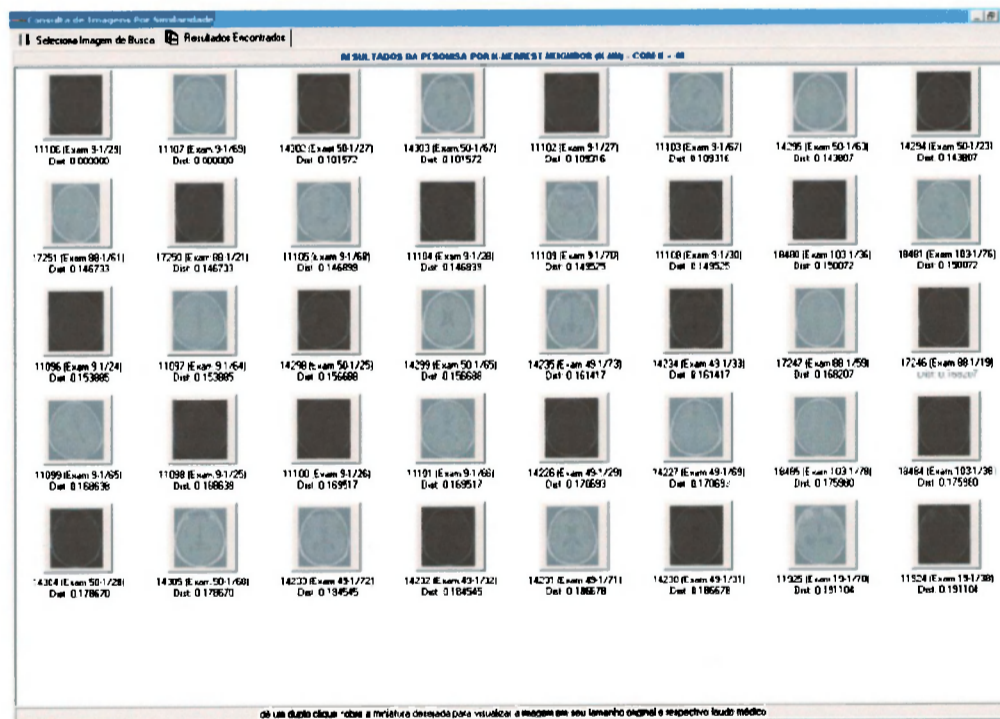


Figura 5.22: Consulta aos vizinhos mais próximos através do Histograma Métrico adaptado.

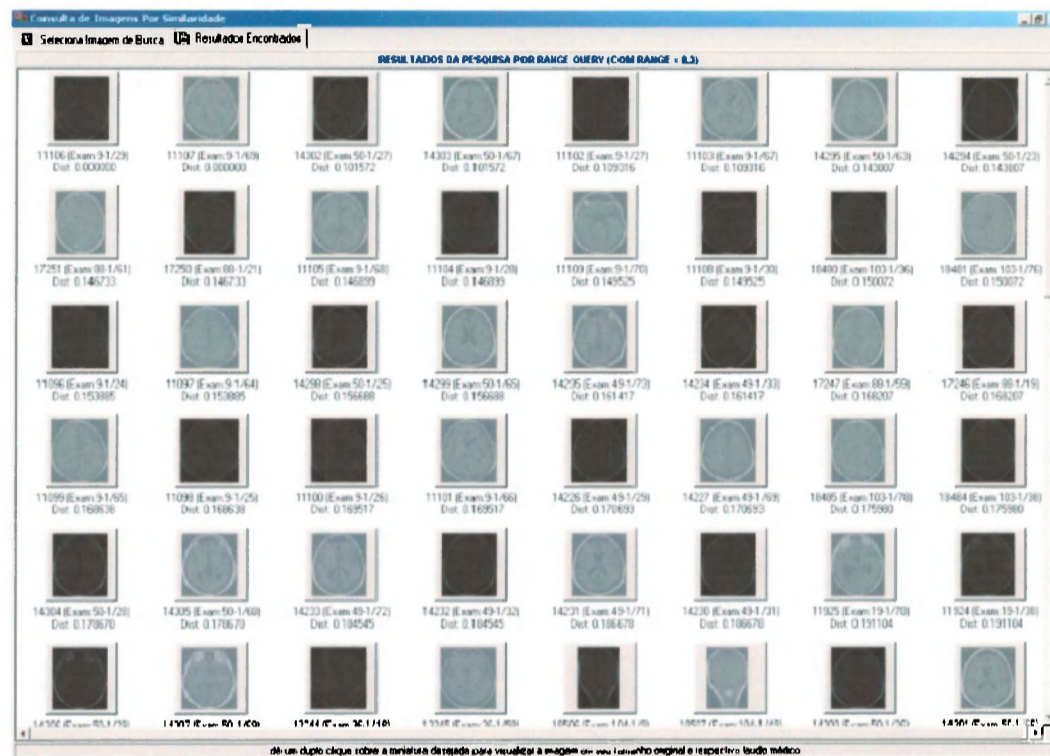


Figura 5.23: Consulta por abrangência com raio de 0.3 utilizando o Histograma Métrico adaptado.

especificar um número limite utilizado para ignorar valores não significativos. Esse valor gira em torno de 0,5% do valor total do histograma. Os resultados mostram que a abordagem utilizada é eficiente e supera claramente abordagens já consolidadas como o BIC.

A recuperação de imagens, através de formas dos objetos presentes na mesma, poderá ser incorporada a este sistema. A grande dificuldade de utilizar abordagens baseadas na forma é o alto custo e pouca precisão de segmentação automática dos objetos de interesses nas imagens.

Caso	Tipo de histograma na Árvore Métrica	Consulta	Critério	Imagens Resultantes	Tempo de busca	Tempo de visualização	Figura
1	normalizado	<i>k-nn</i>	k=40	40	< 1s	8s	5.20
1	normalizado	<i>rq</i>	r=0,3	31	< 1s	6s	5.21
1	métrico	<i>k-nn</i>	k=40	40	< 1s	7s	5.22
1	métrico	<i>rq</i>	r=0,3	130	< 1s	23s	5.23
2	normalizado	<i>k-nn</i>	k=40	40	< 1s	6s	A.2
2	normalizado	<i>rq</i>	r=0,3	43	< 1s	8s	A.3
2	métrico	<i>k-nn</i>	k=40	40	< 1s	7s	A.4
2	métrico	<i>rq</i>	r=0,3	279	< 1s	86s	A.5
3	normalizado	<i>k-nn</i>	k=40	40	< 1s	7s	A.7
3	normalizado	<i>rq</i>	r=0,3	5	< 1s	< 1s	A.8
3	métrico	<i>k-nn</i>	k=40	40	< 1s	7s	A.9
3	métrico	<i>rq</i>	r=0,3	22	< 1s	2s	A.10
4	normalizado	<i>k-nn</i>	k=40	40	< 1s	19s	A.12
4	normalizado	<i>rq</i>	r=0,3	30	< 1s	18s	A.13
4	métrico	<i>k-nn</i>	k=40	40	< 1s	28s	A.14
4	métrico	<i>rq</i>	r=0,3	110	< 1s	51s	A.15

Tabela 5.3: Resumo dos resultados obtidos nos experimentos.

Conclusão e Trabalho Futuros

6.1 Considerações Finais

Sistemas de recuperação de imagens por conteúdo (CBIR) têm se tornado muito importantes para o desenvolvimento de diversas áreas científicas de utilizam imagens. O reconhecimento de objetos através de imagens tem sido empregado não só na medicina, mas em sistemas industriais, de navegação, de segurança ou até em reconhecimento de superfícies. Na área médica, sistemas CBIR avançam rapidamente, pois a potencialidade de aplicações é bastante grande, desde utilização para ensino e estudo de casos até suporte ao diagnóstico por imagens. Além disso, o fato de auxiliar a qualidade de vida com a introdução de sistemas tecnológicos, traz uma motivação social adicional.

Este trabalho apresentou o desenvolvimento de uma técnica de extração de características de imagens, que está sendo incorporada a um sistema de recuperação de imagens médicas por conteúdo. Tal técnica foi desenvolvida modificando uma proposta inicial de tratamento de histogramas de brilho (Histogramas Métricos), sendo que esta nova técnica foi testada e comparada com outra baseada também em histogramas (BIC). Além da extensão realizada no sistema SRIS-HC para incorporar tal técnica, foi também desenvolvido um protótipo de avaliação que utilizado para validar a técnica e comparar com outras propostas em desen-

volvimento no GBDI. Deve-se ressaltar que a pesquisa bibliográfica efetuada foi de fundamental importância já que apresentou o estado-da-arte nos sistemas CBIR. Tais sistemas foram analisados e verificados quais poderiam ser aplicados na área médica. Infelizmente, poucos sistemas tratam com exclusividade imagens monocromáticas (tons de cinza) e menos ainda imagens médicas, onde a variabilidade de intensidades de cinza pode ser baixa. Essa característica traz o problema de que as imagens são homogêneas, não havendo muita discrepância entre informações de imagens distintas. Apesar dos problemas de recuperação das imagens médicas, o presente trabalho apresentou resultados satisfatórios, mesmo comparado com sistemas da literatura.

A utilização do sistema no Hospital das Clínicas permite que os médicos avaliem e comparem diagnósticos anteriores, possibilitando um melhor tratamento ao paciente. A integração do SRIS-HC junto ao sistema de laudo possibilita também uma ferramenta de ensino e validação de diagnóstico médico podendo ser usado por especialistas do HCRP que é um hospital escola.

6.2 Trabalhos Futuros

As técnicas de extração de características baseadas em histograma mapeiam a distribuição global de brilho das imagens e, dessa forma, atuam como um filtro inicial do conjunto de imagens que possa se qualificar a responder consultas por similaridade. Técnicas mais avançadas, baseadas em textura e forma, podem ser incorporadas para atuarem como um processo secundário de seleção do conjunto de imagens resultantes, ou mesmo como um processo inicial, conforme desejado. A incorporação de métodos como forma e contorno da imagem estão em desenvolvimento no GBDI-USP e poderão ser integradas ao sistema SRIS-HC. Por utilizar bibliotecas desenvolvidas pelo próprio grupo de pesquisa como a DicomLib, a adição de componentes pode ser realizada de maneira simples e fácil.

Um estudo mais detalhado sobre as reais necessidades dos médicos poderia ajudar a desenvolver sistemas mais amplos e gerais para as diversas modalidades médicas. A rejeição ao uso de ferramentas computacionais automáticas ainda existe em diversos setores da sociedade e mesmo em centros médicos. A introdução do sistema, que hoje está restrita a um ambiente de testes, para ser utilizado no cotidiano da prática médica traria informações vitais para a sua expansão e boa utilização. O sistema contou com a opinião de diversos profissionais da área, mas ainda não foi testado no dia-a-dia de um hospital onde as imagens geradas diariamente podem chegar a dezena de milhares.



Referências Bibliográficas

- [Albuz et al., 2001] Albuz, E., Kocalar, E., and Khokhar, A. A. (2001). Scalable color image indexing and retrieval using vector wavelets. *IEEE Transactions on Knowledge and Data Engineering*, 13(5):851–861.
- [Aslandogan and Yu, 1999] Aslandogan, Y. A. and Yu, C. T. (1999). Techniques and systems for image and video retrieval. *IEEE Transactions on Knowledge and Data Engineering*, 11(1):56–63.
- [Beckmann et al., 1990] Beckmann, N., Kriegel, H.-P., Schneider, R., and Seeger, B. (1990). The r*-tree: An efficient and robust access method for points and rectangles. In *ACM Int'l Conference on Data Management (SIGMOD)*, pages 322–331.
- [Brown, 1992] Brown, L. G. (1992). A survey of image registration techniques. *ACM Computing Surveys*, 24(4):325–376.
- [Brunelli and Mich, 2001] Brunelli, R. and Mich, O. (2001). Histograms analysis for image retrieval. *Pattern Recognition*, 34(8).
- [Bueno, 2002] Bueno, J. M. (2002). *Suporte à Recuperação de Imagens Médicas baseada em Conteúdo através de Histogramas Métricos*. Tese de doutorado, Universidade de São Paulo.
- [Campo, 2002] Campo, C. Y. (2002). Utilização de histogramas adaptativos para recuperação de imagens por conteúdo em um sistema pacs. Qualificação de mestrado, ICMC - USP.

- [Campo and Traina, 2003] Campo, C. Y. and Traina, A. M. J. (2003). *Uma abordagem eficiente para recuperação de imagens médicas*, cd-rom Cd-rom. III Workshop de Informática Médica, Fortaleza - Ceará.
- [Cao and Huang, 2000] Cao, X. and Huang, H. (2000). Current status and future advances of digital radiography and pacs. *IEEE Engineering in Medicine and Biology Magazine*, 9(5):80–88.
- [Caritá, 2002] Caritá, E. C. (2002). Vinculação de imagens para busca e visualização a partir de sistema de informação em radiologia (ris). dissertação, Departamento de Engenharia Elétrica da Escola de Engenharia de São Carlos - Universidade de São Paulo (USP), São Carlos.
- [Caritá and Marques, 2000] Caritá, E. C. and Marques, P. M. A. (2000). Vinculação de imagens para busca e visualização a partir do sistema de informação em radiologia (ris). In *VII Congresso Brasileiro de Informática em Saúde e do II Simpósio Internacional de Sistemas de Informação Hospitalar*, São Paulo - SP.
- [Castleman, 1996] Castleman, K. R. (1996). *Digital Image Processing*. Prentice-Hall Inc.
- [Chan and McCarty, 1990] Chan, K. and McCarty, K. (1990). Aspects of the statistical texture analysis of medical ultrasound images. In *Ultrasound Instrumentation, IEE Colloquium on*, pages 3/1–3/3. Application Theoretical or Mathematical. TY - CONF.
- [Chua et al., 1997] Chua, T. S., Tan, K.-L., and Ooi, B. C. (1997). Fast signature-based color-spatial image retrieval. In *Multimedia Computing and Systems '97. Proceedings., IEEE International Conference on*, pages 362–369, Dept. of Inf. Syst. & Comput. Sci., Nat. Univ. of Singapore, Singapore. Practical Theoretical or Mathematical Experimental. TY - CONF.
- [Chávez et al., 2001] Chávez, E., Navarro, G., Baeza-Yates, R., and Marroquín, J. I. (2001). Searching in metric spaces. *to appear in the ACM Computing Surveys*.
- [Ciaccia and Patella, 1998] Ciaccia, P. and Patella, M. (1998). Bulk loading the m-tree. In *ADC Australasian Database Conference*, pages 15–26.
- [Ciaccia et al., 1997a] Ciaccia, P., Patella, M., Rabitti, F., and Zezula, P. (1997a). Indexing metric spaces with m-tree. In *Atti del Quinto Convegno Nazionale SEBD*, pages 67–86, Verona, Italy.

- [Ciaccia et al., 1997b] Ciaccia, P., Patella, M., and Zezula, P. (1997b). M-tree: An efficient access method for similarity search in metric spaces. In Jarke, M., editor, *Intl. Conf. on Very Large Databases (VLDB)*, pages 426–435, Athens, Greece.
- [Claude et al., 2001] Claude, I., Pouletaut, P., Huault, S., and Boulanger, J. (2001). Integrated color and texture tools for colposcopic image segmentation. In *Image Processing, 2001. Proceedings. 2001 International Conference on*, volume 2, pages 311–314 vol.2. Application. 'TY - CONF.
- [Faloutsos, 1996] Faloutsos, C. (1996). *Searching Multimedia Databases by Content*. Kluwer Academic Publishers, Boston, MA.
- [Faloutsos and Kamel, 1994] Faloutsos, C. and Kamel, I. (1994). Beyond uniformity and independence: Analysis of r-trees using the concept of fractal dimension. In *ACM Symp. on Principles of Database Systems (PODS)*, pages 4–13, Minneapolis, MN. ACM Press.
- [Furuie et al., 1999] Furuie, S., Bertozzo, N., Figueiredo, J., and Yamaguti, M. (1999). Archiving and retrieving long-term cineangiographic images in a pacs. *Computers in Cardiology*, pages 435–438.
- [G. Günther, 1999] G. Günther, R. A. B. (1999). Large-scale pac systems. In Verlag, S., editor, *Filmless Radiology*, page 21. E.L.Siegel, R.M.Kolodner, New York.
- [Gonzalez and Woods, 1993] Gonzalez, R. C. and Woods, R. E. (1993). *Digital Image Processing*. Addison-Wesley.
- [Gudivada and Raghavan, 1995] Gudivada, V. N. and Raghavan, V. V. (1995). Design and evaluation of algorithms for image retrieval by spatial similarity. *ACM Transactions on Information Systems*, 13(2):115–144.
- [Guttman, 1984] Guttman, A. (1984). R-tree : A dynamic index structure for spatial searching. In *ACM Int'l Conference on Data Management (SIGMOD)*, pages 47–57, Boston, MA. ACM Press.
- [Haralick et al., 1973] Haralick, R. M., Shanmugan, K. S., and Dunstein, I. (1973). Textural features for image classification. *IEEE Trans. SMC*, 3(6):610–621.
- [Jain and Dubes, 1988] Jain, A. K. and Dubes, R. C. (1988). *Algorithms for clustering data*. Prentice-Hall Inc., Englewood Cliffs, NJ.

- [Keogh, 2002] Keogh, E. J. (2002). Exact indexing of dynamic time warping. In Bernstein, P. A. et al., editors, *VLDB 2002: proceedings of the Twenty-Eighth International Conference on Very Large Data Bases, Hong Kong SAR, China, 20-23 August 2002*, pages 406-417, Los Altos, CA 94022, USA. Morgan Kaufmann Publishers.
- [Korn et al., 1996] Korn, F., Sidiropoulos, N., Faloutsos, C., Siegel, E. L., and Protopapas, Z. (1996). Fast nearest neighbor search in medical image databases. In *Intl. Conf. on Very Large Databases (VLDB)*, pages 215-226, Bombay, India. Morgan Kaufmann.
- [Krishnamachari and Abdel-Mottaleb, 1998] Krishnamachari, S. and Abdel-Mottaleb, M. (1998). A scalable algorithm for image retrieval by color. In *Image Processing, 1998. ICIP 98. Proceedings. 1998 International Conference on*, pages 119-122 vol.3, Philips Lab., Briarcliff Manor, NY, USA. Practical. TY - CONF.
- [Kruskal, 1956] Kruskal, J. B. (1956). On the shortest spanning subtree of a graph and the traveling salesman problem. *Proc. American Math Soc.*, 7:48-50.
- [Lima et al., 1998] Lima, L. R. S. d., Laender, A. H. F., and Ribeiro-Neto, B. A. (1998). A hierarchical approach to the automatic categorization of medical documents. In *ACM CIKM*, pages 132-139, Bethesda, Maryland.
- [Loew, 2000] Loew, M. H. (2000). *Feature Extraction*, chapter 5. SPIE, Bellingham, WA, m.sonka and j. michael fitzpatrick edition.
- [Marques and et. al, 2004] Marques, P. M. d. A. and et. al (2004). Projeto ciupe - grupo de estudos em sistemas para auxílio ao diagnóstico por imagem. Internet.
- [Marques et al., 2000] Marques, P. M. d. A., Santos, A. C., Júnior, J. E., Goes, W. M., and Castro, C. R. (2000). Implantação de um sistema de informação em radiologia em hospital universitário. *Radiologia Brasileira*, 33:155-160.
- [Marsh, 1997] Marsh, A. (1997). Euromed - the creation of a telemedical information society. In *10' IEEE Symposium on Computer Based Medical Systems*, pages 86-91, Maribor, Slovenia.
- [Moghaddam et al., 2000] Moghaddam, B., Biermann, H., and Margaritis, D. (2000). Image retrieval with local and spatial queries. In *Image Processing, 2000. Proceedings. 2000 International Conference on*, volume 2, pages 542-545 vol.2, Mitsubishi Electr. Res. Lab., USA. Theoretical or Mathematical. TY - CONF.

- [Pass et al., 1996] Pass, G., Zabih, R., and Miller, J. (1996). Comparing images using color coherence vector. In *ACM Multimedia*, pages 65–73, Boston, MA. ACM Press.
- [Petrakis and Faloutsos, 1997] Petrakis, F. G. and Faloutsos, C. (1997). Similarity searching in medical image databases. *IEEE Transactions on Knowledge and Data Engineering*, 9(3):435–447.
- [Petrakis et al., 2001] Petrakis, E. G., Faloutsos, C., and Lin, K.-I. D. (2001). Imagemap: An image indexing method based on spatial similarity. *IEEE Trans. on Knowledge and Data Engineering*, to appear.
- [Pressman, 2002] Pressman, R. S. (2002). *Engenharia de Software*. McGraw-Hill, Rio de Janeiro, 5.ed. edition.
- [Rao et al., 1999] Rao, A., Srihari, R., and Zhang, Z. (1999). Spatial color histograms for content-based image retrieval. In *Tools with Artificial Intelligence, 1999. Proceedings. 11th IEEE International Conference on*, pages 183–186. Practical Theoretical or Mathematical Experimental. TY - CONF.
- [Rosa, 2002] Rosa, N. A. (2002). Uma abordagem prática e eficiente de consultas por similaridade para suporte a diagnóstico por imagens. Master's thesis, Universidade de São Paulo, São Carlos.
- [Rubner and Tomasi, 2000] Rubner, Y. and Tomasi, C. (2000). *Perceptual Metrics for Image Database Navigation*. Kluwer Academic Publishers, Boston.
- [Russ, 1995] Russ, J. C. (1995). *The Image Processing Handbook*. CRC Press, Boca Raton, 2nd edition.
- [Siegel, 1999] Siegel, E. L. (1999). Current state of the art and future trends. In Siegel, E. L. and Kolodner, R. M., editors, *Filmless Radiology*, pages 3–20. Springer Verlag, New York City, NY.
- [Siegel and Kolodner, 1999] Siegel, E. L. and Kolodner, R. M. (1999). *Filmless Radiology*. Springer Verlag, New York City, NY.
- [Siegel and Reiner, 1999] Siegel, E. L. and Reiner, B. I. (1999). Challenges associated with the incorporation of digital radiography into a picture archival and communication system. *Journal of Digital Imaging*, 12(2):6–8.

- [Smeulders et al., 2000] Smeulders, A. W. M., Worring, M., Santini, S., Gupta, A., and Jain, R. (2000). Content-based image retrieval at the end of the early years. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(12).
- [Stehling et al., 2000] Stehling, R. O., Nascimento, M. A., and Falcaõ, A. X. (2000). On “shapes” of colors for Content-Based image retrieval. In *Proceedings of the ACM 2nd Intl. Multimedia Information Retrieval 2000 Workshop*, pages 171–174, Los Angeles, CA. ACM Press.
- [Stehling et al., 2002] Stehling, R. O., Nascimento, M. A., and Falcaõ, 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*, pages 102–109. ACM Press.
- [Stricker and Dimai, 1996] Stricker, M. and Dimai, A. (1996). Color indexing with weak spatial constraints. In *Storage and Retrieval for Image and Video Databases IV - SPIE*, volume 2670, pages 29–41, San Jose - CA.
- [Sung et al., 2000] Sung, M., Kim, M., Sung, M.-W., Kim, E., and Yoo, J. (2000). Comed: A real-time collaborative medicine system. In *13th IEEE Symposium on Computer-Based Medical Systems (CBMS'00)*, Houston, Texas. IEEE Computer Society.
- [Swain and Ballard, 1991] Swain, M. J. and Ballard, D. H. (1991). Color indexing. *IJCV: International Journal of Computer Vision*, 7:11–32.
- [Theodoridis and Koutroumbas, 1999] Theodoridis, S. and Koutroumbas, K. (1999). *Pattern Recognition*. Academic Press, New York.
- [Traina, 2001] Traina, A. J. (2001). *Suporte à Visualização de Consultas por Similaridade em Imagens Médicas através de Estruturas de Indexação Métrica*. Tese de livre-docente em computação, Instituto de Ciências Matemática e de Computação - Universidade de São Paulo, São Paulo - Brasil.
- [Traina et al., 2002a] Traina, A. J. M., Traina, Caetano, J., Bueno, J. M., and Marques, P. M. d. A. (2002a). The metric histogram: A new and efficient approach for content-based image retrieval. In *Sixth IFIP Working Conference on Visual Database Systems*, Brisbane, Australia.

- [Traina et al., 2002b] Traina, Caetano, J., Traina, A. J. M., Faloutsos, C., and Seeger, B. (2002b). Fast indexing and visualization of metric datasets using slim-trees. *IEEE Transactions on Knowledge and Data Engineering*, to appear.
- [Traina et al., 2000] Traina, Caetano, J., Traina, A. J. M., Seeger, B., and Faloutsos, C. (2000). Slim-trees: High performance metric trees minimizing overlap between nodes. In Zaniolo, C., Lockemann, P. C., Scholl, M. H., and Grust, T., editors, *Intl. Conf. on Extending Database Technology*, volume 1777 of *Lecture Notes in Computer Science*, pages 51–65, Konstanz, Germany. Springer.
- [Tuceryan and Jain, 1993] Tuceryan, M. and Jain, A. (1993). Texture Analysis. in *Handbook of Pattern Recognition and Computer Vision (C.H. Chen, L.F. Pau, and P.S.P Wang, eds)*, pages 235–276. World Scientific Publishing Company.
- [Vailaya, 2000] Vailaya, A. (2000). *Semantic Classification in Image Databases*. Phd. dissertation, Michigan State University.
- [Wilson and Martinez, 1997] Wilson, D. R. and Martinez, T. R. (1997). Improved heterogeneous distance functions. *Journal of Artificial Intelligence Research*, 6:1–34.
- [Yamamoto et al., 1999] Yamamoto, H., Iwasa, H., Yokoya, N., and Takemura, H. (1999). Content-based similarity retrieval of images based on spatial color distributions. In *Image Analysis and Processing, 1999. Proceedings. International Conference on*, pages 951–956, Grad. Sch. of Inf. Sci., Nara Inst. of Sci. & Technol., Japan. Theoretical or Mathematical. TY - CONF.

Demais Resultados

A seguir são apresentados os resultados para os casos 2, 3 e 4.

A.1 Caso 2

A imagem de referência do caso 2 é apresentada na Figura A.1 e o resultado de suas consultas nas Figuras A.2, A.3, A.4 e A.5.




Figura A.1: Imagem de referência do Caso 2.

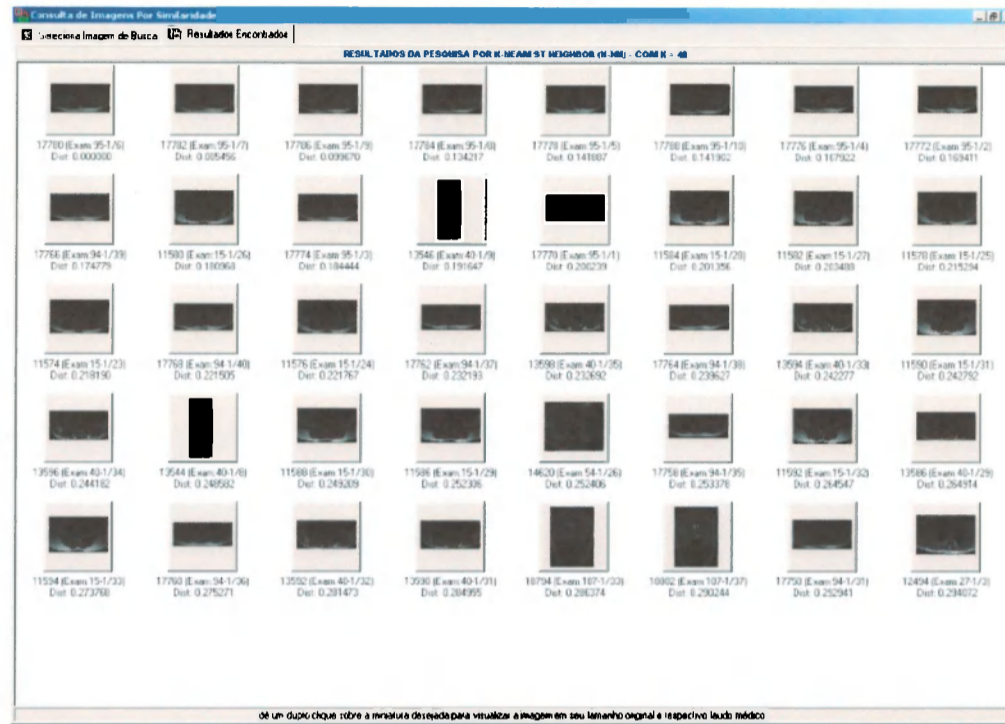


Figura A.2: Consulta aos 40 vizinhos mais próximos utilizando o histograma normalizado.

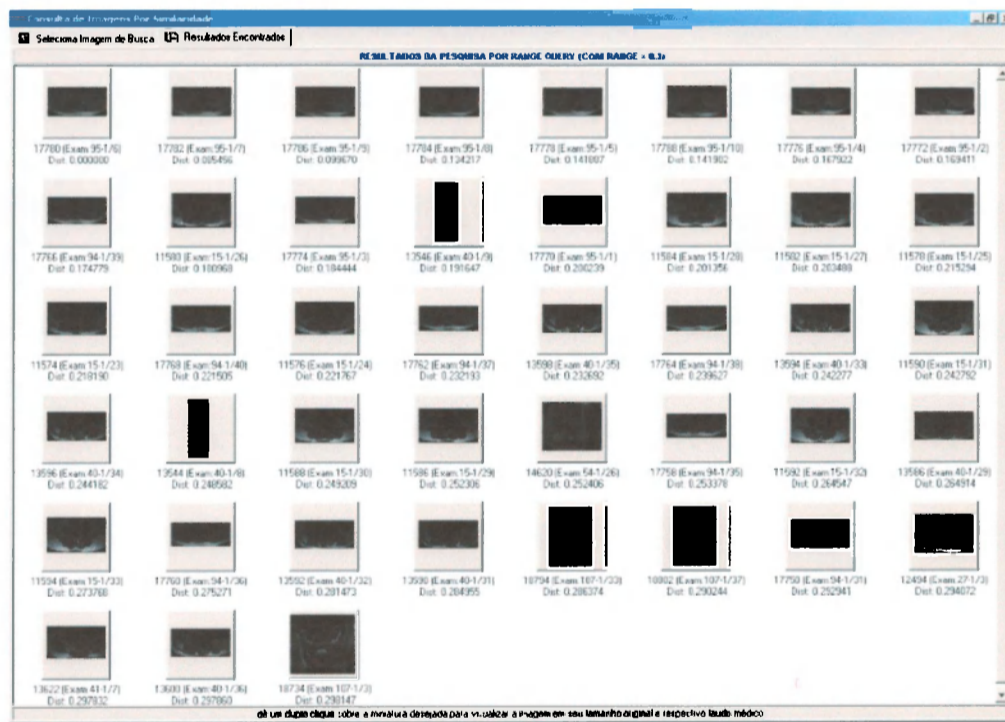


Figura A.3: Consulta por abrangência ($r = 0.3$) utilizando o histograma normalizado.

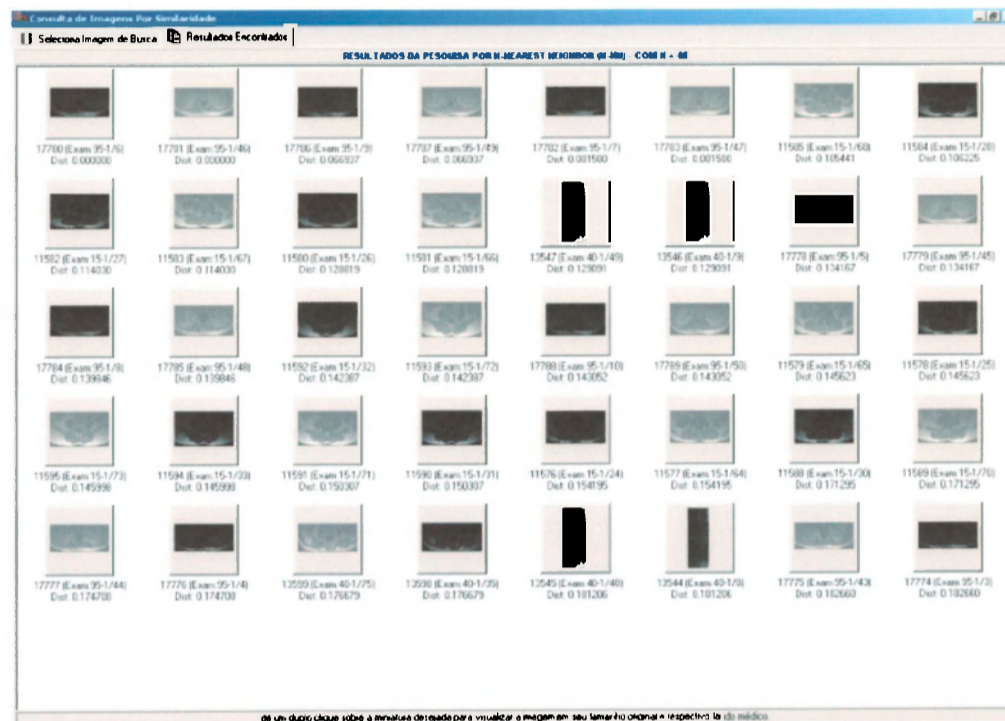


Figura A.4: Consulta aos 40 vizinhos mais próximos utilizando o Histograma Métrico adaptado.

A.2 Caso 3

A imagem de referência do Caso 3 é apresentada na Figura A.6 e o resultado de suas consultas nas Figuras A.7, A.8, A.9 e A.10.

A.3 Caso 4

A imagem de referência do Caso 4 é apresentada na Figura A.11 e o resultado de suas consultas nas Figuras A.12, A.13, A.14 e A.15.

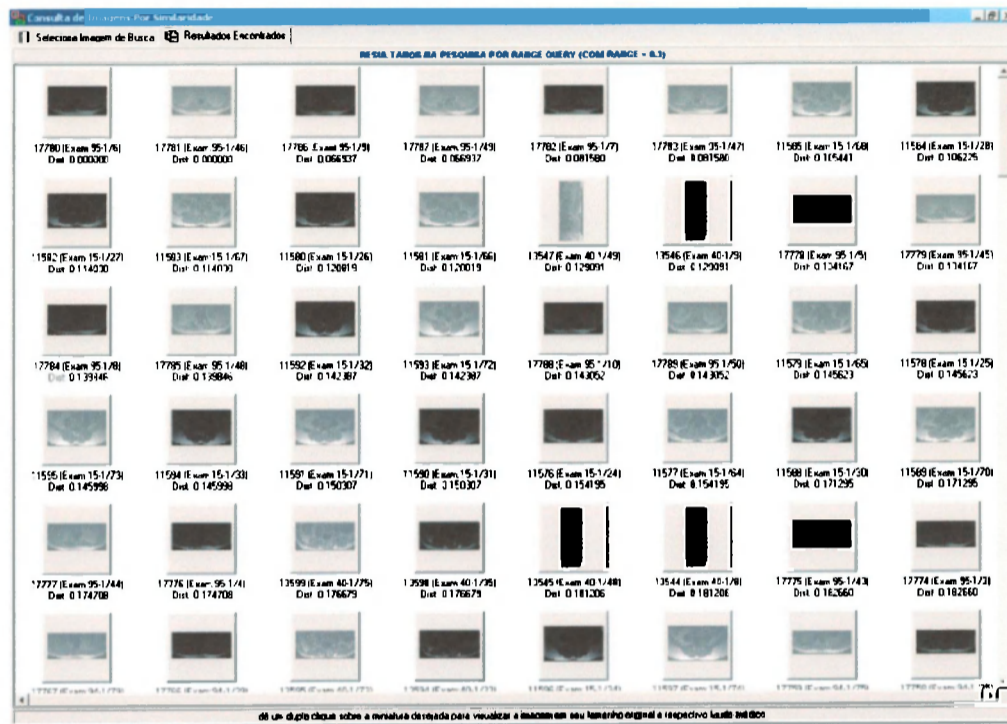


Figura A.5: Consulta por abrangência ($r = 0.3$) utilizando o Histograma Métrico adaptado.




Figura A.6: Imagem de referência do Caso 3.

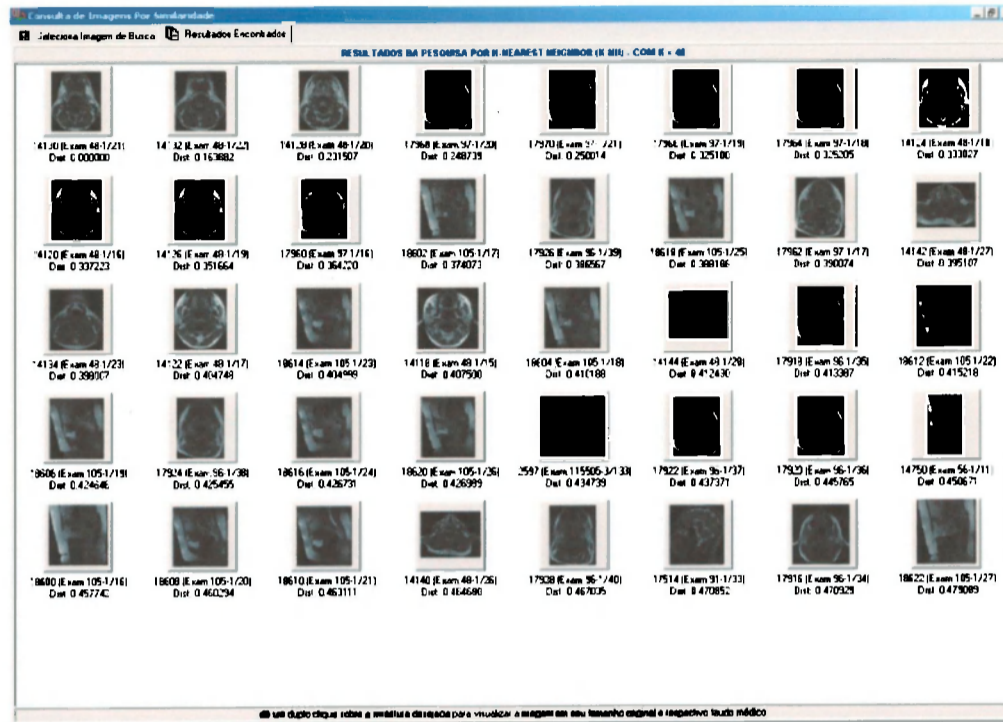


Figura A.7: Consulta aos 40 vizinhos mais próximos utilizando o histograma normalizado.

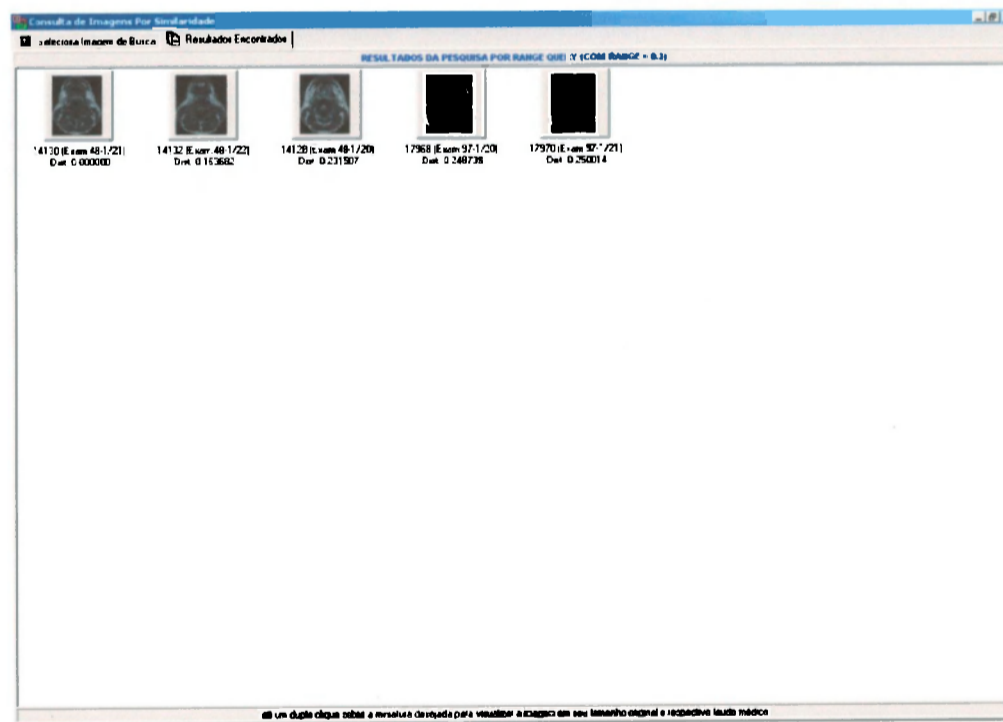


Figura A.8: Consulta por abrangência ($r = 0.3$) utilizando o histograma normalizado.

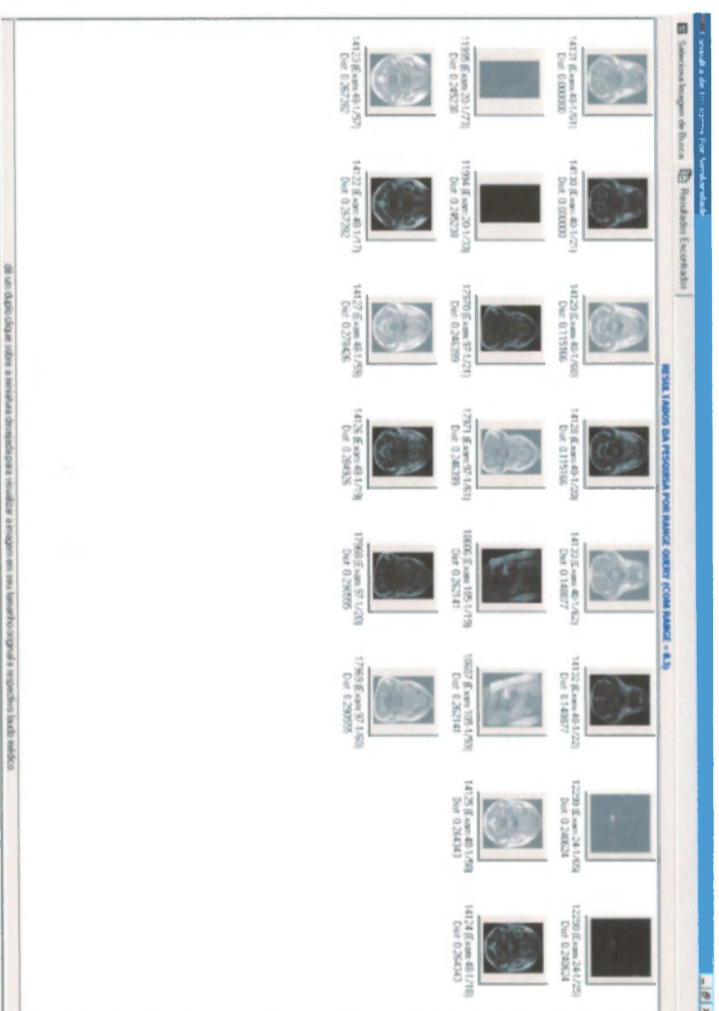


Figura A.10: Consulta por abrangência ($r = 0.3$) utilizando o Histograma Métrico adaptado.




Figura A.11: Imagem de referência do Caso 4.

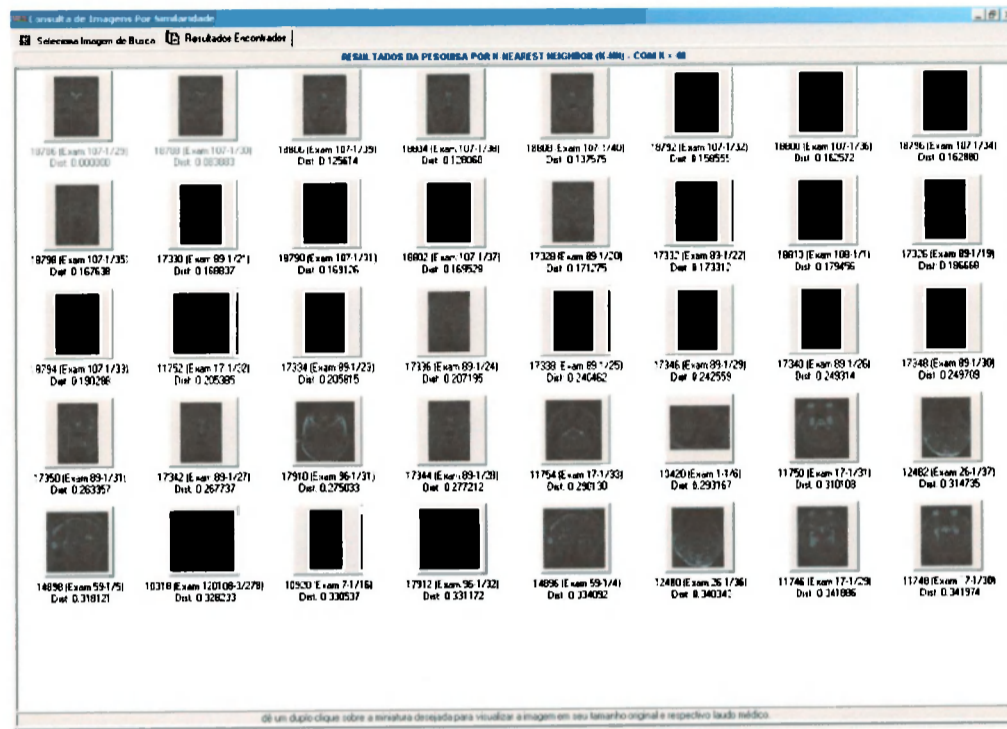


Figura A.12: Consulta aos 40 vizinhos mais próximos utilizando o histograma normalizado.

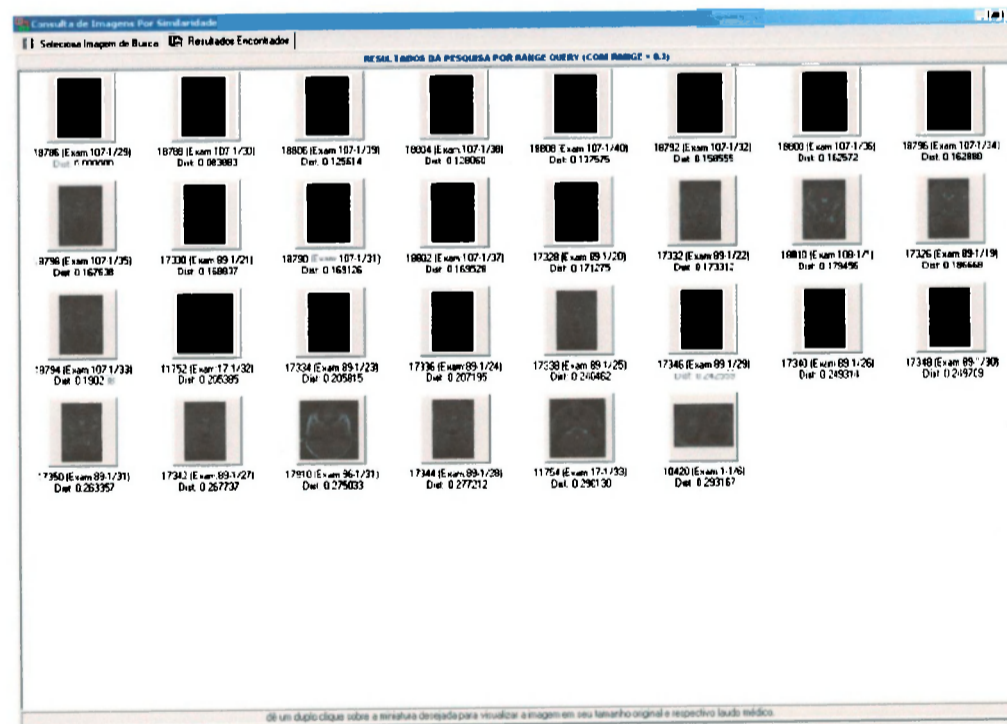


Figura A.13: Consulta por abrangência ($r = 0.3$) utilizando o histograma normalizado.