

Capítulo

1

Recuperação de imagens baseada em conteúdo e sua aplicação na área de saúde

Fátima L. S. Nunes and Márcio E. Delamaro

Abstract

Content-Based Image Retrieval (CBIR) systems allow the research of images using other images as reference for the retrieval. The focus of such systems is to search in a database a certain amount of images similar to a model image, according to one or more provided criteria. Similarity criteria are obtained from feature extraction such as color, texture and shape. Besides being a tool to execute queries in databases of medical images, the concepts of CBIR can be used to evaluate computer-aided diagnosis (CAD) systems. This course introduces the concepts related to CBIR systems, addressing basic settings necessary for the construction of this type of system and their application in medical images retrieval and CAD system validation.

Resumo

Os sistemas de recuperação de imagens baseada em conteúdo (CBIR - Content-Based Image Retrieval) permitem a pesquisa de imagens utilizando outras imagens como referência para a busca. O foco de tais sistemas é pesquisar em um banco de dados uma determinada quantidade de imagens similares a uma imagem de consulta, de acordo com um ou mais critérios fornecidos. Os critérios de similaridade são obtidos a partir da extração de características da imagem como cor, textura e forma. Além de ser uma ferramenta para consultas a bases de imagens médicas, os conceitos de CBIR podem ser utilizados para avaliar sistemas de auxílio ao diagnóstico (computer-aided diagnosis - CAD). Este curso apresenta os conceitos relacionados aos sistemas CBIR, abordando as definições básicas necessárias para a construção de um sistema desta natureza e sua aplicação na recuperação de imagens médicas e na validação de sistemas CAD.

1. Introdução

Tradicionalmente as pesquisas em bases de imagens utilizam palavras-chaves (Lin, Liu and Fuh, 2007), que consistem em atributos textuais, numéricos, ou similares. Para tanto, deve-se previamente cadastrar descritores capazes de definir uma imagem para, então, viabilizar consultas a partir dos mesmos. No entanto, esta forma tradicional torna difícil a pesquisa quando se deseja comparar, por exemplo, uma imagem fornecida pela saída de um programa com outra já conhecida. O conceito de CBIR (*Content-Based Image Retrieval*) vem suprir esta necessidade.

Atualmente CBIR é definido como qualquer tecnologia que ajude a organizar arquivos digitais de imagens por meio do seu conteúdo visual (Datta *et al.*, 2008). De forma geral, os sistemas de CBIR são sistemas computacionais que visam a localizar em uma base de imagens aqueles objetos mais similares a um objeto de consulta, de acordo com um ou mais critérios fornecidos. Os critérios de similaridade são obtidos a partir da extração de características da imagem como cor, textura e forma. Os sistemas automatizados de CBIR envolvem várias áreas da Computação, sendo as principais Processamento de Imagens e Banco de Dados.

Os conceitos de CBIR vêm sendo aplicados em diversas áreas, mas é no campo da saúde que têm encontrado as mais variadas e desafiadoras aplicações. A funcionalidade mais divulgada é na busca de casos para auxiliar na composição de um diagnóstico, em que uma imagem é utilizada como modelo para buscar casos semelhantes em uma base de dados e, assim, verificar diagnósticos atribuídos às imagens resultantes. Uma proposta inovadora é utilizar tais conceitos para avaliar sistemas de auxílio ao diagnóstico.

Os sistemas de auxílio ao diagnóstico (*Computer-aided Diagnosis – CAD*) oferecem uma segunda opinião sobre um diagnóstico, sendo que a maioria deles tem imagens médicas como dados principais de entrada. Um dos desafios do processo de desenvolvimento de sistemas CAD é o estabelecimento de métricas automatizadas para sua avaliação. Neste contexto, os conceitos de CBIR podem ser uma alternativa viável, compondo técnicas que auxiliem na automatização e na identificação de erros durante a fase de teste de software.

As aplicações que requerem a recuperação de imagens médicas e os sistemas CAD estão deixando de ser apenas campos de pesquisa para estarem presentes na rotina diária dos profissionais de saúde. Assim, discutir a utilização de CBIR no desenvolvimento e validação de tais aplicações é um tema que se torna importante na formação de estudantes e pesquisadores nas áreas de computação e saúde. Em geral, tais tópicos não são abordados em cursos de graduação tradicionais da área de Computação e Informática.

Este minicurso pretende abordar os conceitos de CBIR aplicados à área de saúde, englobando duas vertentes: a busca de imagens similares em bases de dados e a sua utilização para avaliar sistemas de auxílio ao diagnóstico. O objetivo principal é apresentar os conceitos de recuperação de imagens baseada em conteúdo, discutindo requisitos para construção de sistemas com esta finalidade e formas de aplicação desses conceitos na área de saúde, considerando tanto a recuperação de imagens médicas quanto a avaliação de CADs.

Para atingir o objetivo proposto a Seção 2 apresenta conceitos sobre recuperação baseada em conteúdo, importantes para compreender a aplicação para recuperar imagens médicas em um banco de dados, apresentada na Seção 3. Na Seção 4 são disponibilizados conceitos sobre sistemas CAD. Um exemplo de aplicação de CBIR na avaliação de um sistema CAD é apresentado na Seção 5, culminando com as considerações finais na Seção 6.

2. Recuperação baseada em conteúdo

Antes de apresentar os conceitos e componentes de um sistema de CBIR é interessante abordar, de forma breve, os fundamentos que envolvem a formação de uma imagem digital, assim como alguns conceitos sobre Banco de Dados, que constituem a base para compreensão dos conteúdos desta seção.

Ballard and Brown (1982) definem que a formação da imagem ocorre quando um sensor registra a radiação que interagiu com objetos físicos. A imagem é uma representação do objeto físico que pode ser armazenada, manipulada e interpretada de acordo com as necessidades do interessado.

A maioria das imagens digitais considera o espaço bidimensional, sendo definida como $f(x,y)$, onde x e y são as coordenadas espaciais. O valor de f na coordenada espacial (x,y) fornece a intensidade, ou seja, o brilho da imagem no ponto. Os valores assumidos em cada ponto medido são quantificados em um número pertencente a uma escala de valores que representam cores. Em grande parte das aplicações computacionais essas cores são relacionadas a níveis de cinza, sendo atribuído o valor zero à cor mais escura (preto) e o valor máximo M à cor mais clara da escala (branco). Dessa forma, pode-se representar uma imagem como uma matriz onde cada ponto é um valor discreto, conforme é mostrado na Equação 1, onde n e m correspondem à quantidade de colunas e linhas, respectivamente.

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,n-1) \\ f(1,0) & f(1,1) & \dots & f(1,n-1) \\ \vdots & \vdots & \dots & \vdots \\ f(m-1,0) & f(m-1,1) & \dots & f(m-1,n-1) \end{bmatrix} \quad (1)$$

O objetivo de definir matematicamente a imagem é a possibilidade de manipular o seu conteúdo a fim de transformá-la ou retirar dela informações importantes. Ao vasto conjunto de operações que podemos aplicar em uma matriz que representa uma imagem denominamos processamento de imagem.

Cada ponto ou elemento constituinte da matriz-imagem é chamado de “pixel” que é uma abreviação do termo em inglês *picture element*. O pixel é, então, a menor unidade sobre a qual podemos realizar operações. Para essas operações são definidas algumas relações básicas como vizinhança, adjacência, conectividade e distância, importantes para implementação de algoritmos utilizados para a extração de características da imagem.

As técnicas de processamento de imagens são, em geral, divididas em três níveis, cada qual com suas funções específicas: **processamento de baixo nível**: responsável pela remoção de dados indesejáveis e realce de dados importantes; **processamento de nível médio**: responsável pela identificação de formas significativas – a esse processo damos o nome de “segmentação” e **processamento de alto nível**: responsável pela ligação da imagem com algum banco de conhecimento. Exemplos de técnicas aplicadas em imagens médicas podem ser conferidos em Nunes (2006).

Um Banco de Dados (BD) é um conjunto de dados organizados de forma sistemática, de acordo com um modelo pré-definido. Um Sistema Gerenciador de Banco de Dados (SGBD) é constituído por um conjunto de dados associado a um conjunto de programas para acesso a esses dados. O principal objetivo de um SGBD é proporcionar um ambiente tanto conveniente quanto eficiente para recuperação e armazenamento de informações do banco de dados (Silberschatz, Korth and Sudarshan, 2005).

Conforme definem Silberschatz, Korth and Sudarshan (2005), sistemas de banco de dados são projetados para gerir grandes volumes de informações. O gerenciamento de informações implica na definição das estruturas de armazenamento e na definição dos mecanismos para a manipulação dessas informações. Os SGBDs são implementados como um conjunto de programas responsáveis por funções que vão desde armazenar os dados de forma otimizada até indexá-los e recuperá-los com eficiência quando solicitados. Quando se trata de armazenamento de imagens, esses programas devem prever ainda mais eficiência, em função do grande volume de dados que essas representam. A implementação mais comum de SGBD utiliza o Modelo Relacional, no qual os dados são organizados em tabelas, compostas por colunas (que representam cada dado a ser armazenado) e linhas (que representam cada exemplar com valores determinados para as colunas definidas). Por meio de colunas adicionais, pode-se fazer o relacionamento entre uma ou mais tabelas, conforme ilustrado na Figura 1.

Tabela Cliente

cod_cliente	nome
10	João
20	Maria
25	Mário

Tabela Conta

num_conta	data_abert	saldo	cod_cliente
1	01/02/1990	200	20
2	24/08/2000	4000	25
3	16/09/2002	-400	20
4	23/12/2008	5000	10

Figura 1 - Exemplo de tabelas relacionadas em um SGBD implementado com o Modelo Relacional.

Como mencionado, grande parte das pesquisas em bases de imagens utilizam palavras-chaves, que consistem em atributos textuais, numéricos, ou similares, armazenados em bancos de dados. Deve-se previamente cadastrar valores para os atributos a fim de que as consultas sejam viabilizadas. Por exemplo, em uma saída de um programa que resulta em uma imagem, esta pode ser descrita textualmente com as palavras “clara”, “escura”, “baixo contraste” para representar características globais ou,

ainda, “círculo com raio 3”, “triângulo retângulo”, “borda muito irregular” para representar aspectos de estruturas contidas na imagem gerada pelo programa em teste.

Essa forma de recuperação torna difícil a pesquisa quando se deseja comparar, por exemplo, uma imagem fornecida pela saída de um programa com outra já conhecida. Para contribuir com o saneamento desta limitação, as pesquisas em CBIR foram iniciadas na segunda metade da década de 1990 (Datta *et al.*, 2008), proporcionando um diferencial na recuperação de informação quando o assunto a ser pesquisado envolve imagens.

Os sistemas de CBIR visam a localizar em uma base de imagens aquelas mais similares a uma imagem modelo, considerando critérios pré-estabelecidos. De forma simplificada e dentro do contexto deste minicurso, um sistema de CBIR é composto basicamente por três partes: extratores, funções de similaridade e estruturas de indexação (Andaló *et al.*, 2007), conforme o esquema definido na Figura 2, detalhado a seguir.

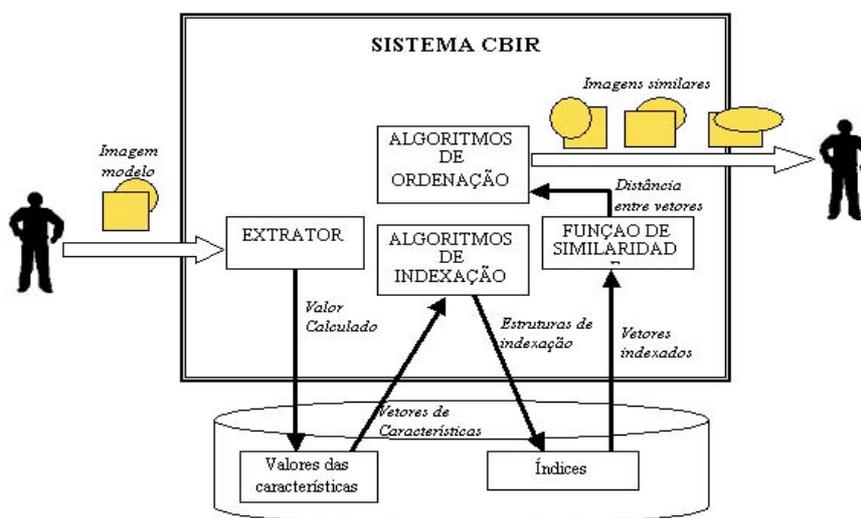


Figura 2 – Esquema simplificado de um sistema de CBIR.

2.1. Extratores

A extração de características de imagens é uma etapa fundamental em um sistema de CBIR. As características representam alguma propriedade (quantitativa ou qualitativa) relativa ao objeto, região ou à imagem toda.

Os extratores são algoritmos capazes de definir características das imagens a partir da análise de cores, formas, texturas ou outros aspectos relacionados à imagem como um todo ou à parte dela. Quando as imagens são consideradas como um conjunto de pixels, esses extratores podem referir-se a relações existentes entre os pixels em um determinado trecho da imagem, considerando uma classe particular de características. Por exemplo, definindo-se as cores como uma classe particular de interesse, um extrator específico poderia retornar o valor do contraste de um determinado trecho da imagem, definindo-o como a média de cores de um objeto segmentado dividida pela média de cores do fundo da imagem (composto pelos pixels que circundam o objeto identificado).

As características extraídas são, em geral, transformadas em um valor que, posteriormente, pode ser comparado com o valor obtido para a mesma característica de outra imagem (El-Naqa *et al.*, 2004). Comumente vários extratores são desenvolvidos em um sistema de CBIR, sendo que cada um deles refere-se a um aspecto da imagem. Por exemplo, o extrator que calcula o contraste de um determinado trecho da imagem, exemplificado anteriormente, pode retornar o valor zero quando o contraste é nulo ou outro valor no intervalo entre zero e um, representando o nível de contraste entre a estrutura considerada e o fundo da imagem. Da mesma forma, um extrator para medir a área de um objeto em uma imagem, poderia retornar o valor 1 quando a área considerada atingisse o maior valor possível.

No processo de extração de características deve ser considerado o foco da aplicação, pois dependendo do tipo de imagem e aplicação, as características de interesse podem variar e até mesmo serem muito específicas. No entanto, é possível definir-se extratores aplicáveis a diversas classes de imagens. O processo de extração de características geralmente ocorre depois de uma etapa de pré-processamento e segmentação da imagem, na qual o objeto de interesse é localizado e rotulado de forma que fique isolado. Na segmentação o objeto é separado do fundo gerando uma região ou apenas identificando a borda (Gonzalez and Woods, 2002). A partir daí o processo de extração de características fica responsável por obter aspectos inerentes ao objeto segmentado ou região de interesse, de acordo com algum critério pré-estabelecido.

Uma região pode ser representada com base em suas características internas (os elementos contidos dentro da região) ou em suas características externas (sua fronteira ou borda) (Gonzalez and Woods, 2002). A representação externa é mais adequada quando o foco está nas características de forma e a representação interna é usada para representar as características como cor e textura. As características que descrevem as imagens devem ser insensíveis às variações de tamanho, translação e rotação, dependendo da sua aplicação.

As características baseadas em intensidades de pixels servem para buscas exatas, ou seja, quando se deseja encontrar imagens exatamente iguais, caso que não se aplica nas consultas por similaridade. As características estatísticas representam o comportamento mais geral da imagem (ou região) e, portanto, são mais utilizadas para uma prévia eliminação de candidatos nas consultas.

Considerando que cada característica obtida é representada por um número dentro de um intervalo (em geral, os valores são normalizados), o conjunto de características extraídas de uma imagem forma o seu vetor de características V , compostos por n elementos, onde n é a quantidade de características armazenadas e V_i é o valor da *iésima* característica daquela imagem. Assim, cada imagem é representada por um vetor de números, utilizado na sua indexação e recuperação. As características extraídas representam a imagem no momento de sua busca. Supondo que foram extraídas as características *área*, *contraste*, *brilho*, *densidade* e *quantidade de nódulos* de uma determinada imagem médica, cujos valores foram normalizados, a Figura 3 ilustra o vetor de característica que seria armazenado para representar esta imagem.

(área)	(contraste)	(brilho)	(densidade)	(quantidade de nódulos)
0,8	0,3	0,9	0,7	0,5

Figura 3 – Exemplo ilustrativo de um vetor de características.

O conjunto de características em si não é suficiente para determinar o resultado da recuperação. Outro elemento que vai influenciar nos resultados da busca é a escolha de medidas de similaridade entre as imagens, apresentadas a seguir.

2.2. Funções de similaridade

Conforme mencionado, os atributos de uma imagem são geralmente obtidos por meio de técnicas de processamento de imagens que medem uma característica e a representam por um número. Esses números formam um vetor de características da imagem. Para aplicar uma consulta por similaridade sobre os vetores de características, Razente *et al.* (2006) lembram que é necessário usar uma função de distância para o cálculo da similaridade, definindo-se a função de similaridade.

Uma função de distância é um algoritmo que compara dois vetores de características e retorna um valor não negativo. Quanto menor o valor retornado, maior é a semelhança entre as imagens representadas pelos vetores. Existem várias funções de distância disponíveis para comparar vetores de características. Alguns exemplos são a distância Euclidiana (Hafner *et al.*, 1995; Swain and Ballard; 1991), a distância de Mahalanobis (Manjunath and Ma, 1996; Smith, 1997) e métricas derivadas de critérios de otimização relacionados (Rubner, Tomasi and L. Guibas, 1998). Vasconcelos (2004) faz uma análise sobre a eficiência da avaliação de sistemas de CBIR usando funções de similaridade probabilísticas. A Equação 2 apresenta a distância Euclidiana, uma das mais simples e mais utilizadas em sistemas de CBIR.

$$D(x, y) = \sqrt{\sum_{i=1}^m (x_i - y_i)^2} \quad (2)$$

Retomando o exemplo anterior, suponha que existam duas imagens, cujos vetores de características sejam representados pelas estruturas $V_1 = [0.8, 0.3, 0.7, 0.9, 0.5]$ e $V_2 = [0.2, 0.5, 0.8, 0.4, 0.9]$. A aplicação da Distância Euclidiana como função de similaridade resultaria no valor 0,9055, o que indica que as imagens são bem diferentes entre si quando consideradas todas as características no cálculo da distância.

2.3. Indexadores

A partir da composição do vetor de características e da definição da função de similaridade a ser empregada, o sistema está pronto para realizar as consultas. As características extraídas representam a imagem no momento de sua busca, pois é a partir delas que uma determinada imagem é recuperada do banco de imagens.

A recuperação por similaridade pode ser por abrangência ou pelos *k-vizinhos* mais próximos. A recuperação por abrangência retorna os elementos cuja distância estão dentro de um raio pré-determinado do elemento modelo. A recuperação pelos *k-vizinhos* mais próximos retorna os *k* elementos que estão mais próximo do elemento modelo (Ciaccia, Patella and Zezula, 1997). Na Figura 4 são ilustrados os dois processos, sendo que o elemento vermelho representa o elemento modelo e os azuis representam os elementos recuperados.

O processo de busca envolve a comparação de vetores de alta dimensionalidade, diretamente relacionada com a quantidade de características desejadas para a pesquisa. Assim, é necessária a otimização do desempenho aplicando-se estruturas de indexação adequadas, envolvendo pesquisas nas áreas de bancos de dados e estruturas de dados. Muitas vezes procura-se diminuir a dimensão dos vetores para, em seguida, construir índices adequados (Bohm, Berchtold and Keim, 2001; Gaede and Gunther, 1998). Estruturas de indexação que consideram apenas a distância existente entre os dados, perfeitamente adequadas ao contexto de CBIR, têm sido objetos de pesquisas há algumas décadas e aperfeiçoadas em trabalhos recentes. Neste contexto, é interessante citar o trabalho pioneiro de Burkhard and Keller (1973) e os trabalhos mais recentes que definem árvores de busca de formas mais otimizadas, direcionadas para aplicações de CBIR (Bohm, Berchtold and Keim, 2001; Gaede and Gunther, 1998; Traina Jr. *et al.*, 2002; Petrakis, Faloutsos and Lin, 2002).

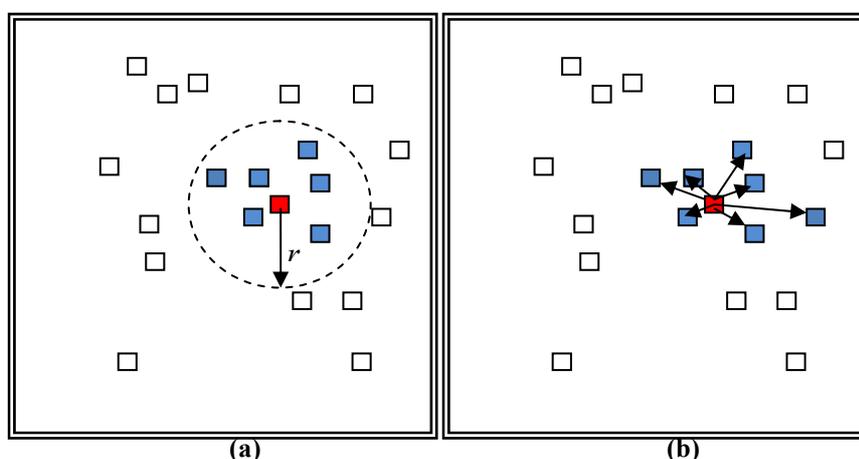


Figura 4 – Esquema de consulta por similaridade: (a) consulta por abrangência, na qual são retornados os elementos com distância menor ou igual ao raio r , em relação ao elemento de interesse; (b) consulta pelos k -vizinhos mais próximos.

Independentemente da forma como é definida a recuperação, de grande importância são as estruturas de armazenamento em BD. Assim, um tópico especial dentro da pesquisa de CBIR são os sistemas de indexação, que não serão aprofundados neste minicurso devido à limitação de escopo e espaço.

2.4. Avaliação de sistemas de CBIR

Um último tópico que merece destaque na construção de sistemas de CBIR é o estabelecimento de métricas para avaliação de sua eficácia.

As medidas de precisão e revocação, também conhecidas por *precision-recall*, são utilizadas para avaliar o desempenho na recuperação de informação (Baeza-Yates and Ribeiro-Neto, 1999) assim como de sistemas de recuperação de imagens (Yamamoto *et al.*, 1999). Estas medidas estão sendo largamente utilizadas na literatura para avaliar sistemas de CBIR, como no caso de Marques *et al.* (2006), André *et al.* (2004), El-Naqa *et al.* (2004) e Traina *et al.* (2002).

De acordo com Traina *et al.*, (2002), considerando um exemplo onde A é a quantidade de imagens relevantes na base de dados, e B é a quantidade de imagens do conjunto resposta de uma determinada busca de imagens por conteúdo, tem-se que:

- **precisão** representa a porcentagem de imagens relevantes que foram recuperadas. Matematicamente, $precisão = \frac{|A \cap B|}{|B|}$;
- **revocação** representa a porcentagem de imagens recuperadas que são relevantes. Matematicamente, $revocação = \frac{|A \cap B|}{|A|}$.

Conforme descrito em Santos (2006), vamos considerar a utilização de um determinado banco de imagens para uma busca por conteúdo, onde um conjunto A possua as imagens relevantes e um conjunto B as imagens recuperadas, sendo $A = \{i_2, i_4, i_5, i_7, i_9\}$ e $B = \{i_5, i_6, i_7, i_1, i_3, i_8, i_9, i_{10}\}$. Supondo que a primeira imagem recuperada seja i_5 , tem-se que esta imagem corresponde a 20% de todas as imagens relevantes; portanto tem uma revocação de 20%. Além disso, ela tem uma precisão de 100% (uma entre uma imagem recuperada é relevante), podendo-se dizer que esta imagem tem uma precisão de 100% em 20% de revocação.

Considerando agora a segunda imagem recuperada que é relevante como i_7 , tem-se que esta imagem tem uma precisão de 66,67% (duas entre três imagens recuperadas são relevantes – observe que i_6 , recuperada em segundo lugar, não faz parte do conjunto de imagens relevantes) em 40% de revocação (foram recuperadas duas imagens relevantes de um total de cinco imagens relevantes). Continuando com a análise descrita, têm-se todos os pontos necessários para se gerar a curva de precisão *versus* revocação (PxR). Caso ao final do conjunto B não tenham sido recuperadas todas as imagens consideradas relevantes, o próximo nível de revocação será igual a zero. Ao final de tal análise, é possível obter-se um gráfico que relaciona a precisão com a revocação, conforme exemplificado na Figura 5. Medindo-se a área entre a curva do gráfico e o eixo x , é possível obter uma métrica para a eficácia do sistema CBIR – quanto mais próxima de 1 for tal área, mais o sistema sob avaliação é considerado eficiente.

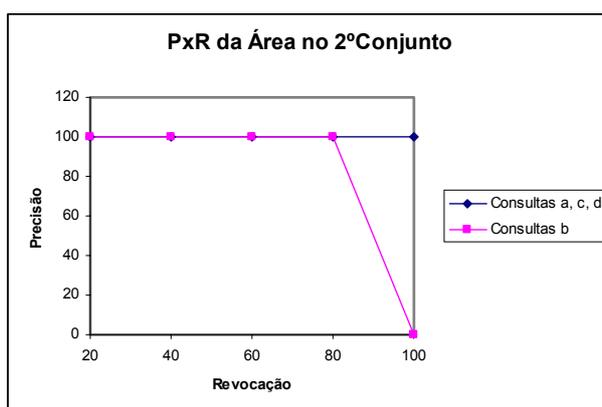


Figura 5 – Exemplo de curva de precisão versus revocação.

3. Recuperação de imagens médicas

Um dos principais campos de aplicação de CBIR é na área de imagens médicas, visto que podem constituir ferramentas úteis para prover aos radiologistas uma forma de auxiliar o diagnóstico a partir da descoberta de imagens similares, considerando uma

determinada patologia. A seguir, será apresentado um exemplo, extraído de Santos (2006), que utiliza os conceitos disponibilizados anteriormente na implementação de um sistema para auxiliar na busca por conteúdo de imagens mamográficas. A mamografia constitui uma forma particular de radiografia, trabalhando com níveis de tensões em intervalos específicos, destinando-se a registrar imagens das mamas a fim de diagnosticar a eventual presença de estruturas indicativas de doenças, sobretudo de câncer (Nunes, 2001).

O sistema apresentado a seguir foi desenvolvido utilizando a linguagem de programação Java e a API (*Application Program Interface*) JAI (*Java Advanced Imaging*) (Sun, 2010). Como SGBD foi utilizado o Derby que é um banco de dados relacional gratuito e inteiramente desenvolvido em Java (Apache, 2010). As imagens utilizadas neste projeto fazem parte de um banco de imagens desenvolvido pelo LAPIMO (Laboratório de Processamento de Imagens Médicas e Odontológicas, da EESC/USP)¹, digitalizadas com 12 *bits* de resolução de contraste (4096 níveis de cinza).

3.1. Segmentação das imagens

Empregando conceitos de processamento de imagens, a primeira tarefa do sistema é a segmentação da área referente à mama, eliminando-se o fundo da imagem, conforme ilustrado na Figura 6. A Figura 7 ilustra o resultado da aplicação do algoritmo para a eliminação do fundo de uma imagem mamográfica.

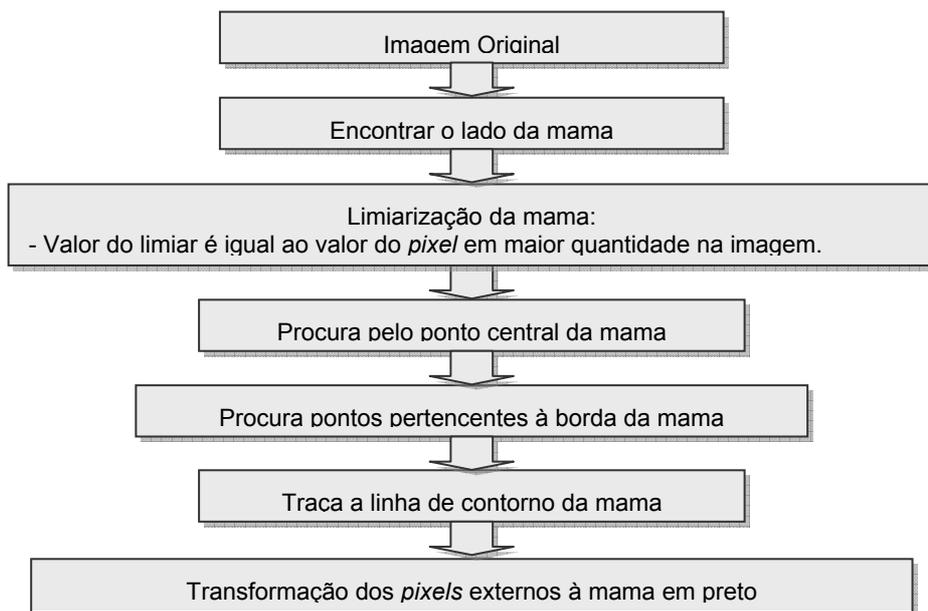


Figura 6 – Esquema geral para o algoritmo de segmentação.

3.2. Extração de características

A partir de um sistema genérico com classes abstratas definidas em Santos (2006), foram implementados os extratores apresentados na Tabela 1. Os três primeiros são autoexplicativos. A seguir são apresentadas explicações adicionais a respeito dos três últimos extratores.

¹<http://www.lapimo.sel.eesc.sc.usp.br>

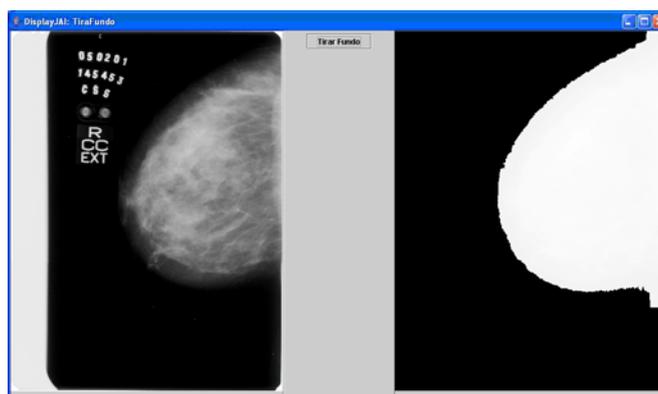


Figura 7 – Exemplo de resultado do algoritmo de segmentação em uma imagem mamográfica.

Tabela 1 – Extratores implementados

Extrator	Descrição
Área	Soma dos <i>pixels</i> da área pertencente a mama dividida pela quantidade total de <i>pixels</i> da imagem.
Densidade	Média dos valores dos <i>pixels</i> da imagem dividida pelo maior valor de pixel possível.
Forma	Divisão da quantidade de <i>pixels</i> do eixo <i>y</i> pela quantidade de <i>pixels</i> no eixo <i>x</i> . Esta quantidade de <i>pixels</i> é encontrada a partir do centro da mama.
Entropia	Representa o grau de desordem dos <i>pixels</i> da imagem.
Segundo Momento Angular	Extraí o nível de homogeneidade da imagem.
Contraste	Identifica as variações locais das imagens.

O extrator de entropia calcula o grau de desordem entre os pixels da região segmentada segundo a fórmula apresentada em Ferrero *et al.* (2006), reproduzida na Equação 3, onde $p(i,j)$ representa o elemento (i,j) normalizado, assim como nas Equações 4 e 5. A partir das fórmulas apresentadas em Ferrero *et al.* (2006), também foram implementados os extratores para obter o *segundo momento angular* e o *contraste*, conforme as Equações 4 e 5, respectivamente, onde N_g é a quantidade de níveis de cinza da imagem.

Essas características têm o objetivo de fornecer uma maneira de medir a textura de uma imagem, sendo obtidas a partir da matriz de co-ocorrência. Segundo Ferrero *et al.* (2006), a matriz de co-ocorrência corresponde à frequência de um nível de cinza na imagem A considerando uma distância em uma direção. A posição $p(i,j)$ indica a frequência de ocorrência de um particular par de nível de cinza i e j , obtido a partir de uma distância e de um ângulo (direção). Considerando uma distância igual a um e um ângulo de 0° , a posição $(0,1)$ da matriz de co-ocorrência é incrementada em uma unidade, caso o valor do elemento à esquerda ou à direita de um *pixel* de valor 0 for igual a 1, como ilustrado na Figura 8 (Ferrero *et al.*, 2006).

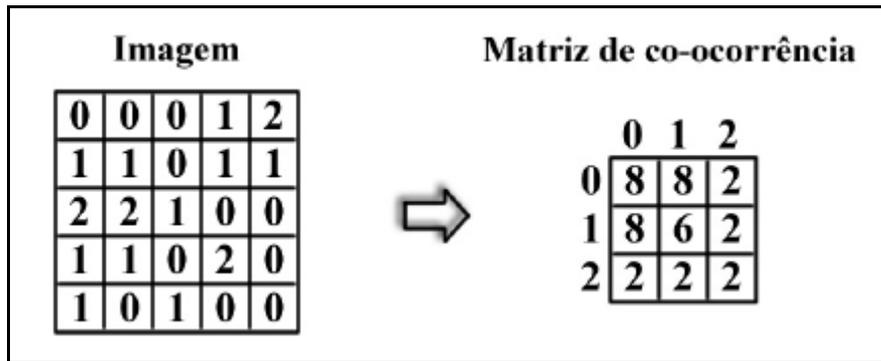


Figura 8 – Exemplo de imagem com três níveis de cinza e sua respectiva matriz de co-ocorrência para distância 1 e ângulo 0° (Ferrero *et al.*, 2006).

$$Entropia = -\sum_i \sum_j p(i, j) \cdot \log(p(i, j)) \tag{3}$$

$$SegundoMomentoAngular = \sum_i \sum_j p(i, j)^2 \tag{4}$$

$$Contraste = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_i \sum_j p(i, j), se |i - j| = n \right\} \tag{5}$$

3.5. Recuperação das imagens

Para a implementação do sistema foi criado um Banco de Dados, conforme o Modelo Relacional apresentado na Figura 9.

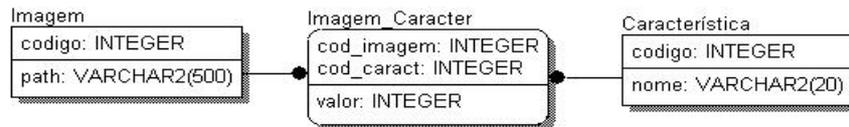


Figura 9 – Diagrama Entidade Relacionamento do sistema.

Para cada imagem do banco de dados são calculadas as características empregando-se os extratores apresentados. Na interface do sistema, ilustrada na Figura 10, o usuário pode selecionar quais características serão utilizadas para a recuperação e também qual será a imagem de referência. Para isto foram criadas caixas de seleção de cada uma das características do banco (parte A da figura), e uma lista com todas as imagens do banco para a seleção da imagem de referência. Quando a imagem é selecionada, sua visualização é automaticamente disponibilizada abaixo da lista de seleção (parte B da figura). Também é permitido ao usuário selecionar quantas imagens deseja recuperar. Quando é selecionado o botão Procurar, é feita a recuperação das imagens mais similares à imagem de consulta considerando as características selecionadas (parte C da figura), utilizando o conceito de *k-vizinhos* mais próximos.

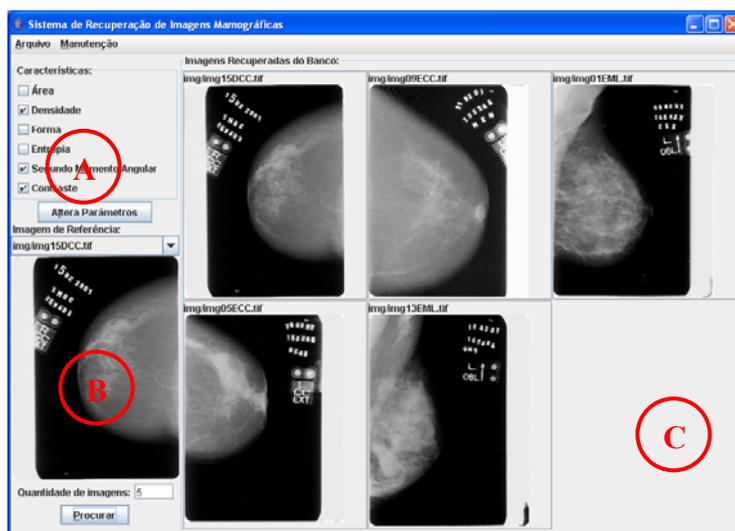


Figura 10 – Exemplo da Interface do sistema

Para avaliar o software construído, foram criados três conjuntos de imagens a saber:

- conjunto com 42 imagens digitalizadas com 16 bits de resolução de contraste;
- conjunto com 20 imagens, sendo 4 imagens reais e da mesma paciente provenientes do primeiro conjunto e 16 imagens obtidas a partir da variação de brilho das imagens (Figura 11);
- conjunto com 16 imagens, contendo quatro imagens originais do primeiro conjunto mais três variações de cada imagem, com inclusão de “manchas” que simulam estruturas de interesse (Figura 12).

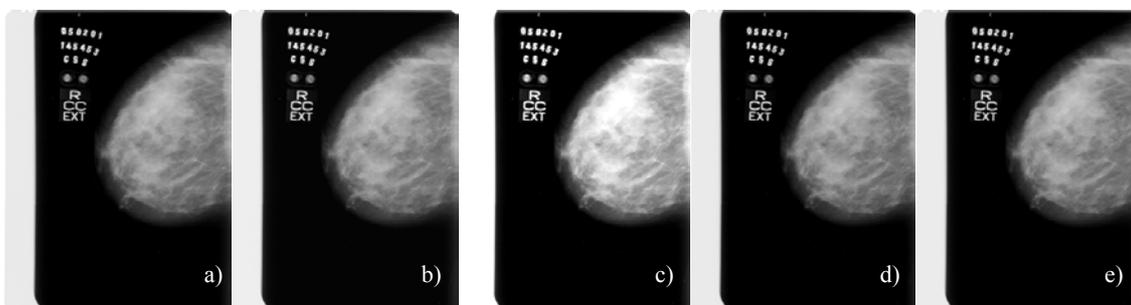


Figura 11 – Exemplo de uma imagem do segundo conjunto com suas variações: (a) imagem original; (b) imagem mais clara com 60 níveis de cinza; (c) imagem mais clara com 1000 níveis de cinza; (d) imagem mais escura com 60 níveis de cinza; (e) imagem mais escura com 1000 níveis de cinza.

Foram avaliados os extratores individualmente e em conjunto. Os resultados completos podem ser verificados em Santos (2006). A seguir são apresentados dois exemplos de resultados, considerando uma característica individual e o conjunto de todas as características.

O primeiro exemplo mostra o resultado usando o extrator de área, que retorna o tamanho da mama na imagem. O resultado da busca no primeiro conjunto de imagens pode ser visualizado na Figura 13a. O resultado do mesmo extrator aplicado no segundo conjunto de imagens mostraram a área como uma medida satisfatória por recuperar as

imagens esperadas, uma vez que retornou as imagens iguais mais claras e mais escuras, conforme ilustrado na Figura 13b.

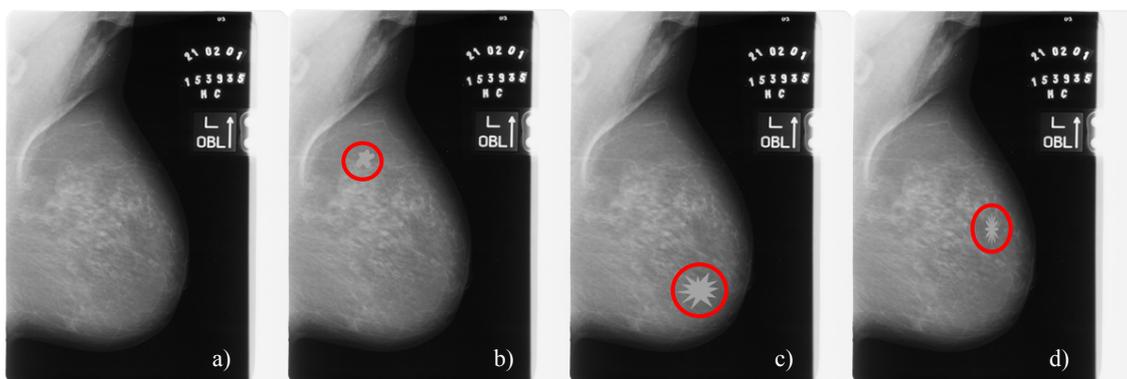


Figura 12 – Exemplo de uma imagem do terceiro conjunto com suas variações: (a) imagem original; (b) imagem com uma mancha de mesmo tamanho, cor e posicionamento; (c) imagem com outra mancha de mesmo tamanho e cor e posicionamento diferenciado; (d) imagem com uma mancha de mesma cor e tamanho e posicionamento variados;

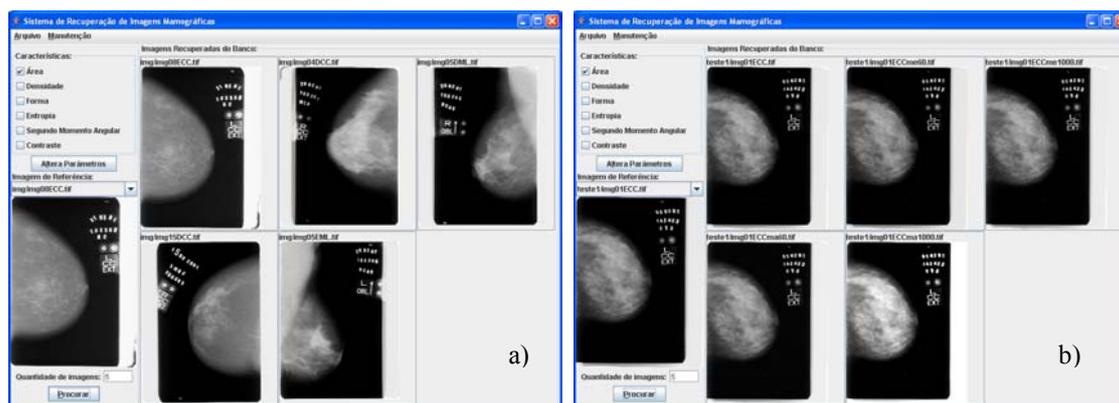


Figura 13 – Interfaces com resultados da recuperação de cinco imagens pela característica “área”: (a) primeiro conjunto de imagens; (b) segundo conjunto de imagens.

Na Figura 14 é apresentado o gráfico de precisão e revocação da característica “área” para o segundo conjunto de imagens, por meio do qual pode-se perceber que a curva da *consulta b* não recuperou todas as imagens esperadas (houve um erro no processo de segmentação, não explorado neste texto). A curva das *consultas a, c, d* refere-se à curva das três outras imagens utilizadas como referência.

O segundo exemplo apresentado envolve a recuperação de imagens no segundo e no terceiro conjuntos de imagens, usando todas as características. Conforme ilustrado na Figura 15, o gráfico de precisão e revocação do agrupamento de todas as características para o segundo conjunto de imagens mostra que o desempenho foi satisfatório com altos níveis de precisão e não recuperando todas as imagens relevantes em apenas uma das consultas. No terceiro conjunto (Figura 16), o desempenho de todas as características agrupadas apresentou níveis de precisão mais baixos do que no segundo conjunto, porém, em todos os conjuntos foram recuperadas todas as imagens consideradas relevantes.

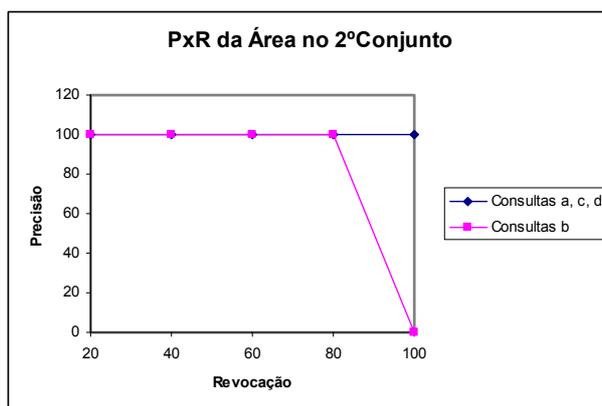


Figura 14 – Precisão e revocação da característica “área” para o segundo conjunto de imagens.

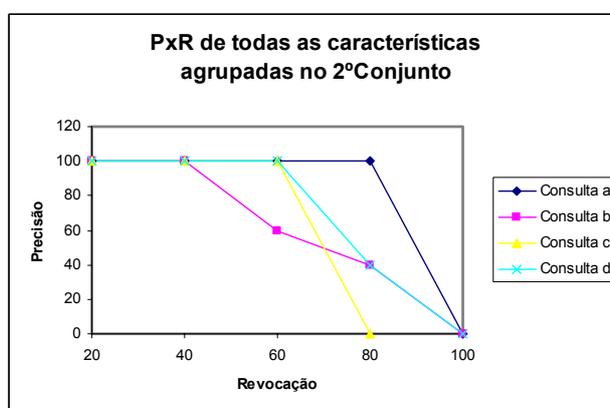


Figura 15 – Precisão e revocação de todas as características agrupadas para o segundo conjunto.

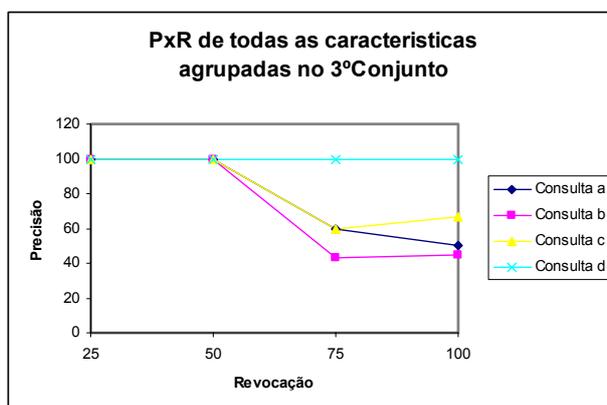


Figura 16 – Precisão e revocação de todas as características agrupadas para o terceiro conjunto.

4. Sistemas de Auxílio ao Diagnóstico

Os sistemas de diagnóstico auxiliado por computador consistem em sistemas computacionais com a finalidade de auxiliar na tomada de decisão a respeito de um diagnóstico (Nunes, 2006). O diagnóstico auxiliado por computador é definido por Giger (2000) como aquele no qual o especialista usa os resultados de uma análise computadorizada de imagens médicas como uma “segunda opinião” na detecção de lesões e na elaboração do diagnóstico. A importância desses sistemas é enfatizada por

Chan *et al.* (1990) e Doi *et al.* (1997), mostrando que o uso de esquemas CAD pode melhorar o desempenho de radiologistas no diagnóstico médico. Esses sistemas constroem uma saída a partir de informações provenientes de diversas fontes, sendo que as imagens médicas de diversas modalidades são as principais delas.

O início da pesquisa desta categoria de sistemas ocorreu nas décadas de 1960 e 1970, quando ainda imaginava-se construir um diagnóstico sem a presença de radiologistas. Na década de 1980, surgiram vários grupos de pesquisa no mundo com o objetivo de desenvolver sistemas CAD para finalidades diversas, tendo principalmente as imagens provenientes de Raios-X como entrada de dados. No final da década de 90, alguns grupos avançaram no desenvolvimento, incluindo imagens de outras modalidades, como Ressonância Magnética Nuclear (RMN) e Ultrassom (US). Nessa década, os primeiros sistemas de CADs começaram a ser aprovados nos Estados Unidos para emprego na rotina médica, como o *ImageChecker*, comercializado pela empresa *R2 Technology*, de Los Altos – Califórnia. (Giger,1998).

Segundo Doi (1997), no desenvolvimento de esquemas CAD, é necessário empregar o processamento de imagem e técnicas para o processamento de informação para uma análise computacional quantitativa, e além disso, compreender a relevância médica das imagens com base nas suas características. No entanto, para se obter sistemas CAD com métodos eficientes, no seu desenvolvimento é necessário empregar técnicas mais recentes, como redes neurais artificiais, transformadas de Wavelet e análise fractal.

Segundo Azevedo-Marques (2001), existem dois tipos de aplicações de sistemas CAD, na área médica: auxílio à detecção de lesões, a partir da localização de padrões anormais e auxílio ao diagnóstico, por meio da quantificação de características da imagem e sua classificação como correspondendo a padrões normais ou anormais.

De forma geral, um sistema CAD é implementado de acordo com as fases apresentadas na Figura 17.

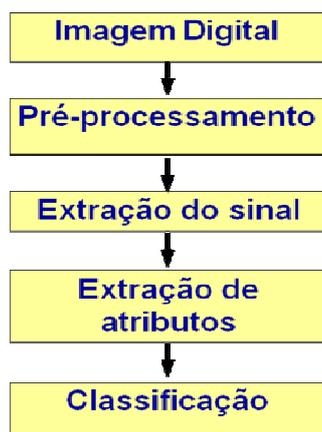


Figura 17 – Fases de processamento em um sistema CAD.

Para que um sistema CAD seja eficiente, é necessário conhecer os princípios envolvidos na formação das imagens médicas utilizadas como fonte de dados, que serão abordados na próxima seção.

4.1. Formação de imagens médicas

Há diversos tipos de imagens médicas, provenientes de equipamentos que fazem a aquisição considerando as propriedades dos materiais. A seguir, são apresentadas as modalidades cujas imagens são atualmente as mais empregadas na construção de sistemas CAD.

A imagem radiográfica se forma em consequência da interação dos fótons de Raios-X com a matéria. Esses fótons atravessam o objeto, sofrendo atenuações, causadas pela sua absorção total ou parcial. O nível de absorção depende dos elementos constituintes desse objeto. Dentro do corpo humano, por exemplo, ossos, músculos e gordura absorvem os fótons considerando diferentes níveis, levando a diferentes atenuações e, conseqüentemente, diferentes intensidades de radiação que chegam ao anteparo no qual a imagem será formada. Isso resulta em diferentes tons de cinza. É essa diferença que possibilita a formação do contraste, permitindo a identificação de estruturas anatômicas (Curry III *et al.*, 1990).

Na Ultrassonografia a imagem se forma quando uma onda sonora é refletida ao chocar-se com a região anatômica em análise. Para formar as imagens da estrutura do corpo humano, esta modalidade utiliza uma faixa de ondas sonoras com uma frequência maior do que a audível para o ser humano. Em aplicações de diagnósticos médicos são utilizadas frequências de 1 a 10 MHz (Bega *et al.*, 2001).

Dainty and Shaw (1976) definem que a Ressonância Magnética Nuclear é baseada nas propriedades magnéticas dos núcleos atômicos, sendo capaz de oferecer detalhes anatômicos e informações estruturais e fisiológicas de forma superior à fornecida por outras modalidades. É capaz de gerar imagens que diferenciem claramente os vários tipos de tecidos moles, mesmo que esses tenham a mesma densidade de massa. O fenômeno de ressonância manifesta-se nos mais diversos tipos de sistemas da natureza, ocorrendo sempre que acontece um estímulo cuja frequência seja próxima à frequência do sistema. No núcleo das células, esta ressonância tem natureza magnética, derivando do fato de certos núcleos terem um momento angular intrínseco chamado spin e um momento magnético associado a ele. Na formação da imagem na RMN, uma das principais propriedades mapeadas é a densidade local dos núcleos atômicos, sendo o hidrogênio o elemento mais utilizado, devido às suas características intrínsecas e também pelo motivo de que o corpo humano possui grande quantidade deste elemento na sua composição. Para gerar as imagens, uma amostra de núcleos é perturbada por uma sequência de pulsos de radiofrequência, emitindo um sinal de RMN para cada um dos núcleos excitados. O registro dos sinais retornados permite a formação da imagem com grande diferenciação entre os tecidos.

Da mesma forma que a radiografia convencional, a Tomografia Computadorizada (TC) baseia-se no princípio de os Raios-X serem apenas parcialmente absorvidos pelo corpo. Enquanto que na radiografia convencional o feixe de Raios-X é piramidal e a imagem obtida é uma imagem de projeção, na TC o feixe é emitido por uma pequena fenda e tem a forma de leque. O tubo de Raios-X gira 360 graus em torno da região do corpo a ser estudada e a imagem obtida é tomográfica, ou seja, são obtidas “fatias” da região investigada. Em oposição ao feixe de Raios-X emitidos, tem-se um detector de fótons que gira concomitantemente ao feixe. Os fótons emitidos dependem da espessura do objeto e da capacidade deste de absorver os Raios-X. Os detectores de

fótons da TC transformam os fótons emitidos em sinal analógico e depois digital (Wilks, 1987).

Cada modalidade de imagem médica responde a um ou mais aspectos presentes nos materiais que compõem os seres da natureza. Assim, cada uma delas tem peculiaridades que as tornam mais ou menos adequadas para o diagnóstico de determinadas doenças.

4.2. Considerações para o desenvolvimento de técnicas computacionais

A finalidade das imagens médicas é auxiliar na composição do diagnóstico de anomalias e fornecer material para acompanhamento de terapias. Cada modalidade tem objetivos específicos e pode apresentar problemas específicos. Na prática, a composição de um diagnóstico pode utilizar imagens adquiridas de modalidades diversas, visto que as limitações de uma modalidade podem ser superadas por características de outra, fazendo com que sejam complementares.

Os diferentes objetivos e os diferentes problemas apresentados pelas modalidades requerem tratamentos diferentes, que exigem a aplicação de técnicas de processamentos de imagens. No tratamento de imagens médicas, é necessário, antes de qualquer decisão, definir-se o objetivo a ser alcançado. Somente após esta definição é possível traçar estratégias a partir da utilização de uma técnica de processamento, da combinação de várias delas ou, ainda, da criação de novas técnicas.

Os sistemas CAD podem contribuir para minimizar as dificuldades na avaliação de imagens médicas, assim como na diminuição de riscos aos pacientes. Entre as principais limitações referentes a esses dois tópicos, é interessante citar (Nunes, 2001):

- a necessidade de controlar a dose absorvida de radiação em imagens provenientes de radiações ionizantes: técnicas de processamento de imagens podem contribuir no sentido de realçar a imagem de acordo com a intensidade desejada, dispensando os aumentos de tempo de exposição, tensão e/ou corrente de tubo (Ishida *et al.*, 1983);
- imagens borradas ou de baixa qualidade devido à aquisição inadequada: sistemas CAD podem melhorar o contraste dessas imagens;
- distorção de estruturas devido à sobreposição de objetos: podem ser parcialmente corrigidos por meio de cálculos matemáticos desenvolvidos a partir de considerações sobre a aquisição das imagens;
- ruídos: podem ser minimizados por filtros de processamento de imagens.

4.2. Exemplos de sistemas CAD

O desenvolvimento de sistemas CAD completos, considerando *software* e *hardware*, exige a participação de equipes multidisciplinares. Além dos profissionais da Computação, são necessárias as habilidades de engenheiros, físicos, estatísticos e especialistas da área de saúde para a qual o sistema está sendo desenvolvido. Na literatura são diversos os sistemas citados visando ao auxílio ao diagnóstico, conforme apresentado a seguir.

Na área de diagnóstico de câncer de mama, um dos grupos mais estabelecidos é o grupo da Universidade de Chicago que desenvolve CAD desde meados da década de 80. Os trabalhos da equipe resultaram no primeiro CAD disponível comercialmente nos Estados Unidos para diagnóstico de câncer de mama². Trabalhos recentes sobre CAD e diagnóstico de câncer de mama auxiliado por computador desses pesquisadores podem ser conferidos em Doi (2007). Os projetos e publicações em relação a desenvolvimento e avaliação de CAD podem ser verificados no site da equipe³.

Ainda relacionado a câncer de mama, Xu, Zhou and Xiao (2007) propuseram um CAD para identificação e classificação de doenças mamárias, usando características de forma de microcalcificações e densidade de nódulos. Yapa and Koichi (2007) apresentaram um algoritmo para identificar componentes conectados em mamogramas.

Para o diagnóstico de doenças pulmonares também há vasta literatura em relação a CADs. Com base nos padrões de tecidos do pulmão e segmentação utilizando características de textura, Shojaii *et al.* (2007) desenvolveram um CAD para diagnosticar cinco tipos de doenças de pulmão a partir de imagens de TC pediátricas. Campadelli, Casiraghi and Valentini (2005) desenvolveram técnicas de segmentação e classificação de nódulos pulmonares. Antonelli, Lazzerini and Marcelloni (2005) apresentaram técnicas para extrair o parênquima pulmonar de imagens de CT a fim de identificar o volume pulmonar. Rao *et al.* (2007) apresentaram o LungCAD, um sistema usado clinicamente para detectar nódulos pulmonares sólidos, em imagens de CT de tórax, afirmando o aumento da eficácia no diagnóstico quando radiologistas usaram o sistema citado.

Dimitrova *et al.* (2007) apresentaram uma interface para auxílio ao diagnóstico de doenças cardíacas, usando processamento de imagens, provenientes de imagens de Ultrassom intravascular, angiogramas e eletrocardiogramas. O sistema utiliza técnicas de segmentação para identificar bordas de vasos para avaliação de estenoses e, em seguida, técnicas de reconstrução de imagens para obter objetos tridimensionais (3D). Também nesta área, Sonka *et al.* (2006) desenvolveram um sistema CAD para identificar riscos de aneurisma em imagens de Ressonância Magnética 4D (imagens 3D acrescidas de tempo), no qual características da superfície e do movimento da aórtica são identificadas por meio de técnicas de segmentação. Syeda-Mahmood, Ponceleon and Yang (2005) capturaram imagens de vídeo e desenvolveram técnicas para medir similaridade de movimentos em imagens cardíacas, como uma forma de auxiliar o diagnóstico nesta área.

Usando processamento de imagens e redes neurais, Zhang and Wang (2007) desenvolveram um CAD para classificar imagens de TC do cérebro em normais ou anormais, usando características de cor, forma e textura e o aspecto de simetria observado em cérebros humanos. Nesse mesmo contexto, Demir, Gultekin and Yener (2005) apresentaram uma representação baseada em grafos para auxílio ao diagnóstico de câncer de cérebro, usando imagens histopatológicas.

Entre as áreas pesquisadas para desenvolvimento de CAD, também é contemplada a detecção de carcinomas de pele por Chaudhry *et al.* (2007) que utilizaram atributos de textura e transformadas *wavelet* para discriminar diferentes tipos de anomalias e o

² www.r2tech.com

³ <http://xray.bsd.uchicago.edu/krl/projects.htm>

diagnóstico de catarata nuclear, por Li *et al.* (2008), que apresentaram uma abordagem para baseada em características de cores e reflexo de imagens provenientes de “lâmpada de fenda”. É interessante citar ainda os trabalhos de Uchiyama *et al.*(2007), que apresentaram um sistema para detectar infartos lacunares assintomáticos em imagens de RMN; Estrabidis and Figueiredo (2007) para diagnóstico de retinopatia diabética, Hao *et al.* (2008) para diagnóstico de hemorragia intracranial infantil e Fang *et al.*(2006) para analisar padrões de imagens 3D de faces a fim identificar síndrome do álcool fetal em imagens de Ultrassom.

4.4. Desafios para avaliação de sistemas CAD

Para que um sistema CAD possa ser aplicado na prática, deve ser submetido a exaustivos testes, considerando uma quantidade considerável de casos, a fim de garantir sua eficácia. Por eficácia, entende-se que o sistema tem que funcionar adequadamente para garantir o diagnóstico de doenças existentes (casos verdadeiros-positivos), mas também não pode diagnosticar doenças inexistentes (casos verdadeiros-negativos). No entanto, uma das questões que se delineia é: como avaliar sistemas diferentes desenvolvidos para a mesma finalidade?

Assim, além da exigência de eficácia, um dos principais desafios no desenvolvimento de sistemas CAD é a sua avaliação, pois os resultados podem variar em função do conjunto de dados de entrada. A avaliação é um desafio citado por Nishikawa *et al.* (1994), que apresentam a dificuldade em estabelecer medidas para comparação entre diferentes sistemas CAD. Para minimizar esta questão são propostas soluções como a disponibilização de bases de imagens comuns e a padronização de critérios de avaliação. Em geral, as avaliações são empíricas e poucas abordagens têm sido apresentadas utilizando técnicas de Engenharia de Software.

Uma das formas mais utilizadas na avaliação do desempenho dos esquemas CAD é a curva ROC (*Receiver Operating Characteristic*) que se tornou padrão obrigatório na avaliação de observadores, devido ao seu caráter gráfico. As curvas ROC são obtidas com base nos resultados que o CAD produz, levando-se em conta a experiência do observador (Metz, 1978). A curva ROC consiste em contrapor a quantidade de acertos (resultados verdadeiros-positivos) e erros (resultados falsos-positivos) do sistema sob avaliação, de forma que uma representação gráfica possa fornecer uma medida de eficiência. Com isso, obtém-se a avaliação do desempenho de um CAD, através da apresentação da relação entre sensibilidade e especificidade (Figura 18).

Apesar de este método ser bastante citado na literatura, observa-se um enorme montante de trabalho para aplicá-lo na avaliação de CADs, considerando-se a seleção de casos e a inspeção visual necessárias. Acrescenta-se a isso a subjetividade envolvida, que pode colocar em dúvida a qualidade do processo de avaliação. Neste sentido, as técnicas de CBIR podem ser verdadeiras aliadas, como apresentado na próxima seção.

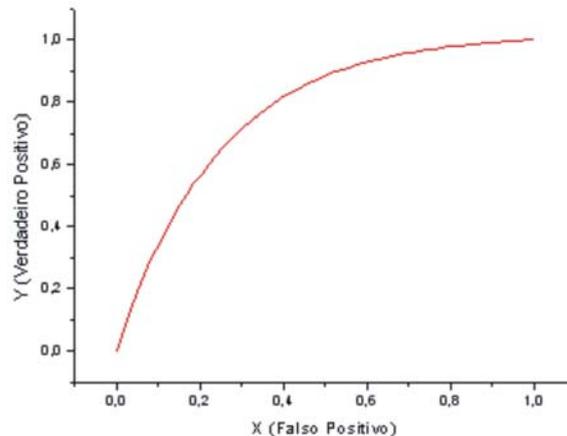


Figura 18 – Exemplo de traçado de uma curva ROC

5. Avaliação de CADs usando conceitos de CBIR

O teste de software é uma das atividades mais caras e, ainda assim, mais importantes no processo de desenvolvimento de software. Por esse motivo, e pela aceitação, entre os pesquisadores e engenheiros de software, da ideia de que qualidade é um fator essencial no desenvolvimento de software, muito se tem investido na pesquisa na área de teste de software.

Nesse contexto, inúmeros aspectos têm sido considerados e a pesquisa nessa área se diversifica em várias linhas como o desenvolvimento de técnicas e critérios de teste (Delamaro, Maldonado and Mathur, 2001), desenvolvimento de ferramentas de suporte (Delamaro, Maldonado and Vincenzi, 2000) aplicações em domínios específicos como sistemas WEB (Emer, Vergilio and Jino, 2005), agentes móveis (Delamaro and Vincenzi, 2003), programas orientados a aspectos (Lemos *et al.*, 2004), para dispositivos móveis (Delamaro, Vincenzi and Maldonado, 2006), entre outros.

Abstraindo algumas características particulares de domínios específicos, a atividade de teste consiste em executar um determinado programa **P**, com um conjunto de dados de teste $\mathbf{I} = \{i_1, i_2, \dots, i_n\}$ e verificar se as saídas produzidas por **P**, $\{P(i_1), P(i_2), \dots, P(i_n)\}$ correspondem às saídas esperadas $\mathbf{O} = \{o_1, o_2, \dots, o_n\}$. Caso exista algum i_k para o qual $P(i_k) \neq o_k$, então um defeito foi revelado. Caso contrário, a execução de **P** sobre **T** contribui para aumentar a confiança de que **P** sempre desempenha sua função, ou seja, está correto.

Uma questão que é ainda mais básica na atividade de teste é como decidir se o comportamento de **P** com um determinado dado de teste é correto ou não. Nem sempre é uma tarefa trivial determinar o conjunto de saídas esperadas **O**.

O mecanismo que se utiliza para definir a saída ou o comportamento esperado de uma execução de **P** é conhecido como “oráculo” (Hoffman, 2001). Num determinado ambiente de desenvolvimento e teste, o oráculo pode assumir diversas formas e deve basear-se na especificação do programa sendo testado. Se essa especificação for, por exemplo, uma definição de requisitos feita informalmente, de maneira textual, provavelmente caberá ao testador desempenhar o papel de oráculo e decidir sobre o comportamento de **P**. Se existe para **P** um modelo formal do qual pode-se extrair seu comportamento, é possível automatizar a função de oráculo construindo-se um

comparador entre a saída produzida e o comportamento definido no modelo. Existem, ainda, os casos em que o oráculo inexistente ou existe apenas de maneira aproximada.

Em algumas situações um oráculo pode basear-se na execução de um outro programa **Q**, para que se decida sobre o resultado da execução de um dado **P**. É o caso do teste de regressão. Ao alterar-se um dado programa **Q**, produzindo-se uma versão atualizada **P**, pode-se decidir sobre a aceitação de **P** através da comparação do comportamento **P(T)** com **Q(T)**, onde **T** é um conjunto de teste sobre o qual **Q** já tenha sido testado e para o qual esteja correto.

Quando se trata de sistemas automatizados de auxílio ao diagnóstico, verifica-se que um oráculo pode ser constituído pela saída de um programa de computador que admite-se estar correto ou, ainda, obtido a partir da prática clínica do usuário. Este último caso é muito empregado na literatura como forma de medir o desempenho de sistemas de auxílio ao diagnóstico, quando comparam-se as saídas de programas a imagens analisadas por radiologistas.

Para auxiliar na automatização de oráculos para programas cuja saída é apresentada na forma de uma imagem, utilizando conceitos de CBIR, foi criado o *framework O-Flm* (Oliveira, Delamaro and Nunes, 2009), que tem como princípio oferecer flexibilidade ao testador possibilitando que se escolha quais serão as características a serem usadas na comparação de imagens. Assim, o testador pode escolher a função de distância e as características que serão utilizadas, configurar como as características devem ser comparadas (parametrização) e adicionar ou instalar novos extratores e funções de similaridade de maneira simples.

A Figura 19 ilustra a maneira como a ferramenta *O-Flm* foi concebida. Um testador configura seu descritor de oráculo (seleciona extratores, parâmetros e funções de similaridade), o *parser* reconhece quais extratores e parâmetros serão utilizados e o núcleo instancia as classes necessárias para o teste e realiza a comparação.

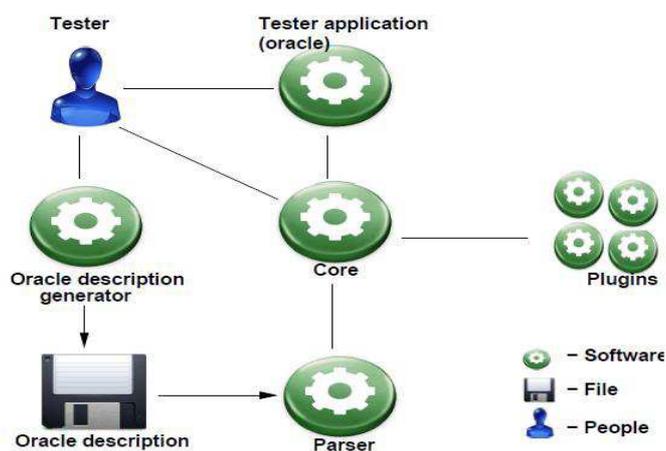


Figura 19 – Arquitetura do *framework O-Flm*.

Para a adaptação de conceitos de CBIR para o funcionamento correto usando o *framework O-Flm*, é necessário que uma classe Java que represente um extrator ou uma função de similaridade implemente as interfaces denominadas *IExtractor*, para extratores, e *ISimilarity*, para funções de similaridade. Uma interface Java descreve

um conjunto de métodos que podem ser chamados em um objeto, porém não são fornecidas implementações concretas para tais métodos. No caso da ferramenta, tais interfaces são um contrato, ou um protocolo, que deve ser seguido por uma classe para que ela seja considerada um acessório *O-Flm* válido.

Para o *framework O-Flm*, as referidas interfaces consistem em alguns métodos que facilitam a manipulação dos extratores escolhidos pelo usuário para serem usados na geração de “oráculos gráficos” e realização de testes de recuperação de imagem. Sendo assim, ao implementar tal interface, um acessório indica para a ferramenta como identificar, localizar e utilizar suas classes no ambiente de um “oráculo gráfico”. Entre os métodos presentes em *IExtractor*, destacam-se *void setProperty(String, Object)* que ajusta uma determinada propriedade para determinado extrator, *String[] getProperties()* que retorna os nomes das propriedades utilizadas pelo extrator e *double computeValue(PlannarImage)* que calcula o valor relativo à propriedade que o extrator implementa, em uma determinada imagem.

O núcleo da ferramenta *O-Flm* permite que o testador instale e remova *plugins* e disponibiliza uma API a partir da qual o testador pode construir seus oráculos. Uma instalação de um extrator ou de uma função de similaridade nada mais é do que a cópia do pacote principal das classes Java de tal extrator para um diretório de conhecimento da estrutura que administrará o ambiente.

Todas as tarefas citadas podem ser configuradas pelo testador. No entanto, para facilitar ainda mais o uso da ferramenta, foi implementada uma ferramenta *Wizard*, que permite a criação dos arquivos de configuração a partir da seleção de opções pelo usuário, conforme ilustra a interface apresentada na Figura 20. Mais detalhes da utilização do *framework* podem ser encontrados em Oliveira, Delamaro and Nunes, (2009).

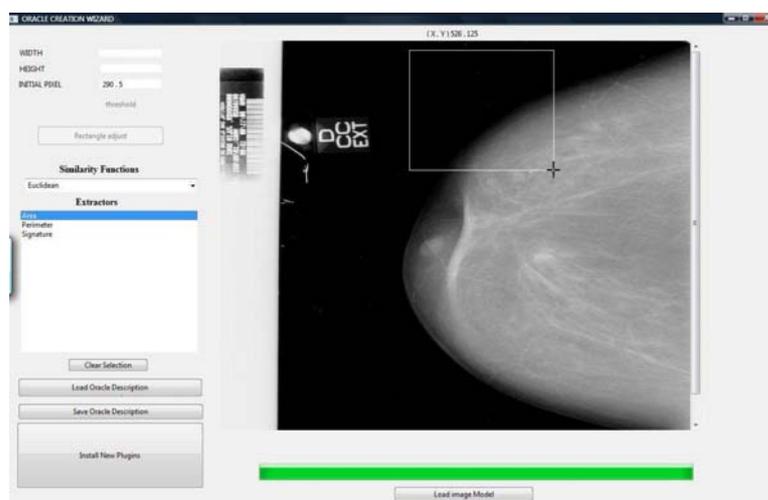


Figura 20 – Tela Principal do Programa - *Oracle Creation Wizard*.

5.1. Estudo de caso com um sistema CAD

Com o objetivo de mostrar como os conceitos de CBIR podem ser utilizados na avaliação de sistemas CAD, foi conduzido um estudo de caso considerando parte de um CAD utilizada para segmentar automaticamente bordas mamárias em imagens mamográficas (Nunes, Delamaro and Oliveira, 2009).

Neste estudo de caso propõe-se a automatização de oráculos de programas cuja saída é apresentada na forma de uma imagem segmentada. Em resumo, tem-se uma ou várias imagens armazenadas que representam a saída esperada de uma execução de um programa CAD e tem-se um segundo conjunto de imagens, resultante da execução desse programa e das quais se deseja verificar a correção. No nosso caso, um conjunto de imagens mamográficas foi manualmente marcado duas vezes, com a finalidade de identificar a região correspondente à mama. Dependendo do caso, essas imagens podem ser avaliadas por mais de um especialista e uma média das avaliações pode ser obtida.

Deve-se notar que a comparação exata não é suficiente para o propósito apresentado, visto que levaria em conta somente a configuração espacial dos pixels presentes em uma imagem. Além das dificuldades de casamento espacial de tais imagens, esta comparação eliminaria possibilidades da flexibilidade necessária quando o fator humano é introduzido no processo (Oliveira, Delamaro and Nunes, 2009).

As imagens demarcadas manualmente são utilizadas como referência para comparação com o resultado de um programa que faz essa identificação de modo automático. A Figura 21 mostra uma imagem mamográfica original (a), a mesma imagem após segmentação automatizada para extração das características (b) e a imagem marcada manualmente, usada como oráculo (c).

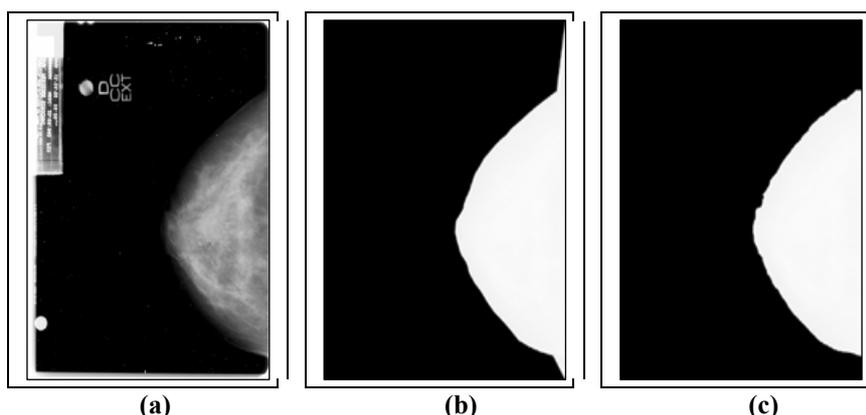


Figura 21 – (a) imagem mamográfica original; (b) imagem segmentada automaticamente e (c) imagem marcada manualmente.

A comparação foi realizada utilizando três extratores (área, perímetro e assinatura) e a distância euclidiana como função de similaridade. O extrator de área faz a contagem da quantidade de pixels presentes dentro da borda da mama e o extrator de perímetro contabiliza os pixels que fazem parte da borda demarcada. O terceiro extrator implementado é uma medida de forma e verifica a diferença entre os formatos das bordas demarcadas. Sua implementação consistiu em discretizar a borda demarcada, selecionando-se pontos igualmente espaçados, considerando um ângulo pré-determinado formado entre o ponto central da área da mama e a fronteira identificada. A Tabela 2 mostra os valores obtidos para a distância entre as duas últimas imagens exibidas na Figura 1, considerando cada um dos extratores isoladamente.

Tabela 2 – Valores dos extratores empregados para a imagem da Figura 1.

Imagem/Extrator	Área	Perímetro	Assinatura
Distância	0,002584	0,001720	0,000292

Conforme pode ser observado visualmente na Figura 21 e comprovado a partir dos valores apresentados na Tabela 2, as imagens comparadas apresentam diferenças na segmentação. Ao calcular a distância Euclidiana especificamente dessas duas imagens, obtém-se o valor aproximado de 0,0031, fornecendo uma medida de similaridade entre elas. Esta medida pode ser analisada pelo testador a partir de um limiar pré-estabelecido, a fim de decidir se o valor é suficiente para considerar que o programa sob teste está apresentando algum defeito. Especificamente em um estudo de caso mais abrangente foram analisadas 30 imagens semelhantes à apresentada e foi estudado o comportamento do programa testado variando-se o valor de limiar e descobrindo-se alguns indícios de defeitos no software. Verificou-se que a utilização dos conceitos de CBIR pode constituir uma abordagem inovadora para testar sistemas CAD (e quaisquer outros tipos de sistemas que tenham imagens como produto resultante), tornando a atividade de teste de software mais automatizada e menos trabalhosa.

6. Considerações finais

Apesar de relativamente novos, os conceitos de CBIR têm sido objeto de pesquisa, explorando-se desde sua arquitetura de seus componentes até sua otimização e o emprego de imagens multimodais. Envolve técnicas avançadas de Computação e profundo conhecimento da área de aplicação, exigindo, por natureza um domínio multidisciplinar do problema. Uma das áreas de aplicação mais exploradas – e também uma das mais promissoras – é a área médica, justamente pela necessidade de armazenamento de imagens multimodais e a recuperação desejada, em tempo hábil e com eficácia, de conteúdos que auxiliem na composição de diagnósticos. Assim, sistemas eficazes podem fornecer aos profissionais da saúde um rico material que os ajudem a tomar decisões por meio da comparação de casos similares.

Apesar do enfoque deste texto contemplar a área médica, os conceitos aqui apresentados são plenamente aplicáveis nas mais diversas áreas de conhecimento, na qual a busca por similaridade seja uma necessidade.

No entanto, desenvolver sistemas de CBIR não é tarefa trivial. Além da já mencionada predisposição para trabalhar em projetos multidisciplinares, é necessário vencer desafios inerentes à Computação (como tempo de resposta, precisão nos resultados e reuso de software) e à área de aplicação, a fim de que seja possível construir extratores, funções de similaridade e indexadores adequados. Delineia-se, portanto, uma rica área de pesquisa e desenvolvimento, passível de abrir caminhos a estudantes e profissionais que desejam aplicar com propriedade os conteúdos aprendidos em sala de aula.

7. Referências bibliográficas

- Andaló, F. A., Miranda, P. A. V. , Torres, R. S. and A. X. Falcão (2007) “A New Shape Descriptor based on Tensor Scale”, In: 8th International Symposium on Mathematical Morphology, p.141–152, Rio de Janeiro, Brazil.
- André, T. C. S. S., Marques, P. M. A., Rodrigues, J. A. H. and Rangayyan, R. M. (2004) “Sistema de Recuperação de Imagens Baseada em Conteúdo Usando Mapas de Kohonen e Técnicas de Correlação Cruzada”, In: IX CBIS, Congresso Brasileiro de Informática em Saúde.

- Antonelli, M., Lazzerini, B. and Marcelloni, F. (2005) "Segmentation and reconstruction of the lung volume in CT images", In: Proceedings of the 2005 ACM Symposium on Applied Computing, p. 255-259.
- Apache Derby, Apache Derby, disponível em: <http://db.apache.org/derby/> acesso em janeiro de 2010.
- Azevedo-Marques, P.M. (2001) "Diagnóstico auxiliado por computador na radiologia", *Radiol. Bras.*, v. 34 (5), p. 285-293.
- Baeza-Yates, R. and Ribeiro-Neto, B. *Modern information retrieval*. New York, ed. Addison-Wesley. 513p. 1999.
- Ballard, D.H and Brown, C.M. *Computer Vision*. Englewood Cliffs, New Jersey, Prentice-Hall Inc., 1982.
- Bega, G., Lev-Toaff, A., Kuhlman, K., Kurtz, A., Goldberg, B. and Wapner, R. (2001) "Three-dimensional ultrasonographic imaging in obstetrics", *J Ultrasound Med., Canadá.*, v. 20, p. 391-408.
- Bohm, C., Berchtold, S. and Keim, D. A. (2001) "Searching in high-dimensional spaces: Index structures for improving the performance of multimedia databases", *ACM Computing Surveys (CSUR)*, v.33(3), p.322-373.
- Burkhard, W. A. and Keller, R. M. (1973) "Some approaches to best-match file searching" *Communications of the ACM*, v.16(4), p. 230-236.
- Campadelli, P. Casiraghi, E. Valentini, G. (2005) "Lung nodules detection and classification", *IEEE Image Processing*, v.1, p. 1117-20.
- Chan,H-P., Doi, K., Vyborny, C.J., Schmidt,R.A., Metz, C.E., Lan, K.L., Ogura,T., Wu,Y. and MacMahon, H. (1990) "Improvement in radiologists' detection of clustered microcalcification on mammograms: the potential of computer-aided diagnosis", *Investigative Radiology*, v. 25, p. 1102-1110.
- Chaudhry, M. L., Ashraf, R., Jafri, M. N and Akbar, M. (2007) "Computer aided diagnosis of skin carcinomas based on textural characteristics", *Machine Vision*, p. 125 - 128
- Ciaccia, P., Patella, M. and P. Zezula. (1997) "M-tree: An Efficient AccessMethod for Similarity Search in Metric Spaces", In: Proceedings of 23rd International Conference on Very Large Data Bases, p.426-435, Athens, Greece.
- Curry III, T. S., Dowdey, J. E. and Murry Jr., R.C *Christensen's Physics of Diagnostic Radiology*, 4. ed., Philadelphia, Lea & Febiger, 1990.
- Dainty, J.C. and Shaw, R. R. M. "Image Science", 3ed., New York, Academic Press, 1976.
- Datta, R., Joshi, D., Li, J., and Wang, J. Z. (2008) "Image retrieval: Ideas, influences, and trends of the new age", *ACM Comput. Surv.* 40.
- Delamaro, M. E. and Vincenzi, A. M. R. (2003) "Structural Testing of Mobile Agents", In: III International Workshop on Scientific Engineering of Java Distributed Applications (FIDJI'2003), Lecture Notes on Computer Science, Springer, p. 73-85.

- Delamaro, M. E., Maldonado, J. C. and Mathur, A. P. (2001) "Interface Mutation: An Approach for Integration Testing", *IEEE Transactions on Software Engineering*, v. 27 (3), p. 228-247.
- Delamaro, M. E., Maldonado, J. C. and Vincenzi, A. M. R. (2000) "Proteum/IM2.0: An Integrated Mutation Testing Environment", In: *MUTATION 2000*.
- Delamaro, M. E., Vincenzi, A. M. R. and Maldonado, J. C. (2006) "A Strategy to Perform Coverage Testing of Mobile Applications", In: *Proceedings of the Workshop on Automation of Software Testing (AST 06)*.
- Demir, C., Gultekin, S. H., and Yener, B. (2005) "Learning the Topological Properties of Brain Tumors", *IEEE/ACM Trans. Comput. Biol. Bioinformatics*, v. 2 (3), p. 262-270.
- Dimitrova, M., Roumenin, C., Lozanova, S., Lahchev, L., Rotger, D. and Radeva, P. (2007) "An interface system based on multimodal principle for cardiological diagnosis assistance", In: *Proceedings of the 2007 international Conference on Computer Systems and Technologies*, v. 285, p. 1-6.
- Doi, K., M. L., Nishikawa, R. M. and Schmidt, R.A (1997) "Computer-aided diagnosis of breast cancer on mammograms", *Breast Cancer*, v.4, n.3, p.228-233.
- Doi, K: Computer-aided diagnosis in medical imaging: Historical review, current status and future potential. *J Comp Med Imaging Graphics* 31: 198-211, 2007.
- El-Naqa, I., Yang, Y. , Galatsanos, N. P. , Nishikawa, R. M. and Wernick, M. N. (2004) "A similarity learning approach to content-based image retrieval: application to digital mammography," *IEEE Trans Med Imaging*, vol. 23, p. 1233-1244.
- Emer, M. C. F. P., Vergilio, S. R. and Jino, M. (2005) "A Testing Approach for XML Schemas", In: *Proceeding of the The 29th Annual International Computer Software and Applications Conference*.
- Estabridis, K. and Figueiredo, R.J.P. (2007) "Automatic detection and diagnosis of diabetic retinopathy", *Image Processing*, v. 2, p. 445-448.
- Fang, J., Fang, S., Huang, J. and Tuceryan, M. (2006) "Digital geometry image analysis for medical diagnosis", In: *Proceedings of the 2006 ACM Symposium on Applied Computing*, p. 217-22.
- Ferrero, C.A., Lee, H. D., Chung, W. F., Coy, C. S. R., Fagundes, J. J. and Góes, J. R. N. (2006) "Seleção de Características Baseadas em Textura para a Identificação de Anormalidades em Imagens de Colonoscopia", In: *X Congresso Brasileiro de Informática em Saúde – CBIS'2006*.
- Gaede, V. and Gunther, O. (1998) "Multidimensional Access Methods", *ACM Computing Surveys*, v.30(2), p.170–231.
- Giger, M. L. Overview of Computer-Aided Diagnosis in Breast Imaging. p. 167-177, 1998.
- Giger, M.L. (2000) "Computer-aided diagnosis of breast lesions in medical images", *Computing in Science & Engineering*, v. 2 (5), p. 39-45.

- Gonzalez, R.C. and Woods, R. E. Digital Image Processing, Addison-Wesley Publishing Company, Massachusetts, 2a. Edição, 2002.
- Hafner, J. , Sawhney, H., Equitz, W. , Flickner, M. and Niblack, W. (1995) “Efficient color histogram indexing for quadratic form distance functions”, IEEE Trans. Pattern. Anal. Machine Intell., v. 17, p. 729–736.
- Hao, B., Leung, C. K., Camorlinga, S., Reed, M. H., Bunge, M. K., Wrogemann, J. and Higgins, R. J. (2008), “A computer-aided change detection system for paediatric acute intracranial haemorrhage”, In: Proceedings of the 2008 C3S2E Conference, v. 290, p.109-111.
- Hoffman, D. (2001) “Using oracles in testing automation”, Pacific Northwest Software Quality Conference (PNSQC 2001).
- Ishida, M., Frank, P.H., Doi, K. and Lehr, J.L. (1983) “High quality digital radiographic images: improved detection of low-contrast objects and preliminary clinical studies”, Radiographics, v.3 (2), p.325-338.
- Lemos, O. A. L., Vincenzi, A. M. R., Maldonado, J. C. and Masiero, P. C. (2004) “Teste de Unidade de Programas Orientados a Aspectos”, In: Anais do 18º Simpósio Brasileiro de Engenharia de Software (SBES 04), p. 55–70.
- Li, H., Lim, J. H., Liu, J., Wong, D. W. K. and Wong, T. Y. (2008) “Computer aided diagnosis of nuclear cataract”, Industrial Electronics and Applications, p.1841 – 1844.
- Lin, Y-Y. , Liu, T-L. and Fuh, C-S. (2008) “Local ensemble kernel learning for object category recognition”, In: Image Retrieval: Ideas, Influences, and Trends of the New Age, Edited by Ritendra Datta *et al.*, ACM Computing Surveys, v.40 (2), p.1–8 .
- Manjunath, B. and Ma, W. (1996) “Texture features for browsing and retrieval of image data”, IEEE Trans. Pattern Anal. Machine Intell., v.18, p. 837–842.
- Marques, J. and Traina, A. J. M. (2006) “Realimentação de Relevância: Integração do Conhecimento do especialista com a Recuperação de Imagens por Conteúdo”, In: VI Workshop de Informática Médica - WIM'2006 (junto ao V Simpósio Brasileiro de Qualidade de Software - SBQS), 2006, p. 83-93.
- Marques, P. M. A., Honda, M. H., Rodrigues, J. A. H., Santos, R. R., Traina, A.J.M., Traina Jr, C. and Bueno, J.M. (2002) “Recuperação de Imagem Baseada em Conteúdo: Uso de Atributos de Textura para Caracterização de Microcalcificações Mamográficas”, Revista Brasileira de Radiologia, v. 35, p. 93-98.
- Metz, C.E. (1978), “Basic Principles of ROC Analysis”, Seminars in Nuclear Medicine, v. 3, n. 4.
- Nishikawa, R. M., Giger, M. L., Doi, K., Metz, C. E., Yin, F-F., Vyborny, C. L. and Schmidt, R. A. (1994) “Effect of case selection on the performance of computer-aided detection schemes”, Medical Physics, v. 21, p. 265-269.
- Nunes, F. L. S. (2006) “Introdução ao Processamento de Imagens Médicas para Auxílio ao Diagnóstico”, In: Atualizações em Informática, Edited by Karin Breitman and Ricardo Anido, 1ed, Rio de Janeiro: PUC-Rio, v.1, p. 73-126.

- Nunes, F. L. S. Investigações em processamento de imagens mamográficas para auxílio ao diagnóstico de mamas densas. Tese (Doutorado), IFSC/USP, S.Carlos (SP), 2001.
- Nunes, F. L. S., Delamaro, M. E. and Oliveira, R.A.P. (2009) “Oráculo gráfico como apoio na avaliação de sistemas de auxílio ao diagnóstico”, In: WIM2009 - IX Workshop de Informática Médica / XXIX Congresso da Sociedade Brasileira de Computação.
- Oliveira, R. A. P., Delamaro, M. E. and Nunes, F. L. S. (2009) “O-FIm – Oracle for Images”, In: Anais dos XXIV Simpósio Brasileiro de Banco de Dados e XXIII Simpósio Brasileiro de Engenharia de Software.
- Petrakis, E. G. M., Faloutsos, C. and Lin, K. I. (2002). “Imagemap: An image indexing method based on spatial similarity”, IEEE Trans. Knowl. Data Eng, v. 14(5), p.979–987.
- Rao, R. B., Bi, J., Fung, G., Salganicoff, M., Obuchowski, N. and Naidich, D. (2007), “LungCAD: a clinically approved, machine learning system for lung cancer detection”, In: Proceedings of the 13th ACM SIGKDD international Conference on Knowledge Discovery and Data Mining, p. 1033-1037.
- Razente, H., Barioni, M. C. N., Traina, A. J. M. and Traina Jr., C. (2006) “Recuperação de Imagens Médicas por Conteúdo em um Sistema de Gerenciamento de Banco de Dados de Código Livre”, In: X Congresso Brasileiro de Informática em Saúde (CBIS), p. 1561-1566.
- Rubner, Y., Tomasi C. and Guibas, L. (1998) “A metric for distributions with applications to image databases”, In: Proc. Int. Conf. Computer Vision, Bombay, India.
- Santos, A. P. O. Recuperação de imagens mamográficas baseada em conteúdo, Trabalho de Conclusão de Curso-Bacharelado em Ciência da Computação, Centro Universitário Eurípides de Marília, 2006.
- Shojaii, R. Alirezaie, J. Khan, G. Babyn, P. (2007) “Automatic honeycomb lung segmentation in pediatric CT images”, IEEE Signal Processing and Its Applications, p. 1 – 4.
- Silberchatz, A., Korth, H. F. and Sundarshan, S. Database System Concepts. 5. ed. McGraw-Hill, 2005.
- Smith, J. (1997) “Integrated spatial and feature image systems: retrieval, compression and analysis”, Ph.D. dissertation, Columbia Univ., New York, 1997.
- Sonka, M. Zhao, F. Zhang, H. Wahle, A. Stolpen, A. Scholz, T. (2006) “Early Detection of Aortic Aneurysm Risk from 4-D MR Image Data”, Computers in Cardiology, p. 69 - 72.
- Sun Microsystems, Java document home page, disponível em: <http://java.sun.com/j2se/1.5.0/docs/api/> acesso em janeiro de 2010.
- Swain, M. and Ballard, D. (1991) “Color indexing”, Int. J. Computer Vision, v.7(1), p.11–32.

- Syeda-Mahmood, T., Ponceleon, D. and Yang, J. (2005) "Validating cardiac echo diagnosis through video similarity", In: Proceedings of the 13th Annual ACM international Conference on Multimedia, p.527-530.
- Traina Jr., C. , Traina, A. J. M. , Faloutsos, C. and Seeger, B. (2002) "Fast Indexing and Visualization of Metric Datasets Using Slim-trees", IEEE Transactions on Knowledge and Data Engineering, v. 14 (2), p. 244-260.
- Uchiyama, Y., Yokoyama, R., Ando, H., Asano, T., Kato, H., Yamakawa, H., Hara, T., Iwama, T., Hoshi, H. and Fujita, H. (2007) "Improvement of Automated Detection Method of Lacunar Infarcts in Brain MR Images", Engineering in Medicine and Biology Society, p. 1599 – 1602.
- Vasconcelos, N. (2004) "On the efficient evaluation of probabilistic similarity functions for image retrieval", IEEE Trans. Inf. Theory, v. 50 (7), p.1482–1496.
- Wilks, R.J. "Principles of Radiological Physics", New York, Churchill Livingstone, 1987.
- Xu, X-M., Zhou, F-L. and Xiao, Y. (2007) "The Study of Mammary Disease CAD System", IEEE Complex Medical Engineering, 2007, p. 676 - 679.
- Yamamoto, H., Iwasa, H., Yokoya, N. and Takemura, H. (1999) "Content-based Similarity Retrieval of Images Based on Spacial Color Distributions", In: 10^o Intl. Conference on Image Analysis and Processing, 1999.
- Yapa, R. D. and Koichi, H. (2007) "A connected component labeling algorithm for grayscale images and application of the algorithm on mammograms", In: ACM Symposium on Applied Computing, p. 146-152.
- Zhang, W-L and Wang, X-Z. (2007) "Feature extraction and classification for human brain CT images", In: Proceedings of the Sixth International Conference on Machine Learning and Cybernetics, p. 1155-1159.