

Processamento e Análise de Imagens Médicas

Medical Image Processing and Analysis

Ana Maria Marques da Silva¹ , Ana Cláudia Patrocínio² , Homero Schiabel³ 

¹Núcleo de Pesquisa em Imagens Médicas, Escola Politécnica, Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, Brasil

²Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, Brasil

³Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, Brasil

Resumo

Este artigo tem por objetivo apresentar uma abordagem conceitual sobre os principais aspectos envolvidos no processamento e na análise digital de imagens médicas, trazendo exemplos da aplicação na prática clínica e da pesquisa em imagens médicas. Para explorar a temática, o artigo está dividido em seções. A primeira seção apresenta os aspectos relacionados às diferenças entre a imagem adquirida no equipamento e a visualizada nos monitores, levantando alguns elementos relacionados à qualidade da aquisição. A seguir são descritas algumas técnicas de pré-processamento que permitem melhorar e destacar aspectos relevantes das imagens. A próxima seção apresenta os principais métodos de segmentação de objetos de interesse nas imagens. A seguir, duas seções descrevem como representar e descrever de forma quantitativa as características relevantes das imagens, para que elas possam ser analisadas computacionalmente, e os aspectos relativos à análise e ao reconhecimento de padrões em imagens. Finalmente, são apresentados alguns exemplos de esquemas de auxílio computadorizado ao diagnóstico.

Palavras-chave: imagens médicas; processamento de imagens; segmentação; auxílio computadorizado ao diagnóstico.

Abstract

This article aims to present a conceptual approach on the main aspects involved in digital medical image processing and analysis, bringing examples of applications in clinical practice and research in medical imaging. To explore the theme, the article is divided into sections. The first section presents the aspects related to the differences between the image acquired in the equipment and viewed in displays, raising some elements related to the quality of the acquisition. Up next, some preprocessing techniques that allow to enhance and highlight relevant aspects of the images are described. The next section introduces the main methods of segmenting objects of interest in images. The following two sections describe how to represent and quantitatively describe relevant features of images so that they can be computed and the aspects of image pattern recognition and analysis. Finally, some examples of computer aided diagnostic schemes are presented.

Keywords: medical imaging; image processing; segmentation; radiology; computer aided diagnostic.

1. Introdução

O corpo humano é um sistema complexo e a aquisição de dados sobre suas propriedades estáticas e dinâmicas produz grandes quantidades de informação. Um dos maiores desafios é como adquirir, processar e exibir dados sobre o corpo, de modo que a informação possa ser visualizada, interpretada e utilizada para permitir sua análise nos procedimentos diagnósticos e auxiliar em terapias. Em muitos casos, a apresentação de informações sobre o corpo humano na forma de imagens é a abordagem mais eficiente para enfrentar esse desafio.

As imagens médicas são produzidas pela interação de algum tipo de energia com os tecidos, órgãos ou sistemas do corpo humano. O processo de produção das imagens médicas está sempre relacionado a alguma forma de interação de um determinado tipo de energia (eletromagnética,

mecânica) com a matéria. A visualização da imagem é realizada através de um parâmetro de contraste, determinado por alguma característica física que diferencia os diferentes tecidos, órgãos ou sistemas. Com exceção da ultrassonografia, que utiliza energia mecânica, a maioria das imagens médicas utiliza a interação entre a energia eletromagnética e o corpo humano. A laparoscopia, por exemplo, utiliza luz visível que interage com os tecidos, enquanto outras imagens médicas utilizam radiações não visíveis, como infravermelho, ultravioleta, raios X ou radiação gama. No caso das não visíveis ao olho humano, a visualização das imagens exige a atribuição de uma escala “falsa” de cores aos valores dos parâmetros de contraste.

Diferentes técnicas de imagens médicas são usadas para revelar a estrutura do corpo (anatomia), sua fisiologia (funções) e as interações bioquímicas entre células e

moléculas que o compõem. Essas três categorias de imagens médicas são usualmente denominadas imagens estruturais, funcionais e moleculares. Separadamente ou combinadas, tais técnicas vêm ampliando consideravelmente a compreensão da estrutura e função do corpo humano.

As tecnologias modernas de imagens médicas oferecem o potencial e a promessa de grandes avanços na medicina. A área de processamento e análise digital de imagens é um dos campos mais importantes da ciência médica devido ao rápido e contínuo progresso na visualização de imagens médicas e avanços nos métodos de diagnóstico assistido por computador e terapias guiadas por imagens. Essa área vem sendo essencial para a detecção precoce, o diagnóstico e a avaliação da resposta ao tratamento do câncer. O desafio é processar e analisar de forma efetiva as imagens médicas de forma a extrair, quantificar e interpretar essas informações para obter compreensão e percepção sobre a estrutura e o funcionamento dos órgãos e sistemas.

Por sua própria natureza, a área de processamento e análise digital de imagens é interdisciplinar em vários aspectos. Primeiro, para a aquisição das imagens devem ser considerados os aspectos envolvidos na sua produção por causa das diferentes propriedades físicas e químicas dos objetos a serem imageados por sistemas de detecção. Em seguida, o parâmetro de contraste da imagem deve ser convertido em sinal digital e processado por um computador para extração das informações. Nessa cadeia de processos estão envolvidos conceitos de várias ciências, tais como computação, física, matemática e química, e contribuições de diversos aspectos da engenharia elétrica, mecânica e de *software*.

Este artigo apresenta uma abordagem conceitual sobre o processamento e a análise digital de imagens, trazendo alguns exemplos da aplicação de tais métodos na prática clínica e da pesquisa em imagens médicas.

Para explorar a temática, optou-se por dividir este artigo em seções que apresentam:

- como as imagens médicas são representadas digitalmente e os principais aspectos relacionados à sua aquisição, como o ruído;
- algumas técnicas de pré-processamento que permitem melhorar e destacar aspectos relevantes das imagens;
- os principais métodos de segmentação de objetos de interesse nas imagens;
- como representar e descrever de forma quantitativa características relevantes das imagens para que elas possam ser analisadas computacionalmente;
- aspectos relativos à análise e ao reconhecimento de padrões em imagens;
- alguns exemplos de esquemas de auxílio computadorizado ao diagnóstico.

2. Representação das Imagens Digitais

2.1. Representação Fotométrica e Faixa Dinâmica

Imagens de câmeras digitais e/ou para internet, de modo geral, são formadas por arquivos que se caracterizam por

apresentarem resolução de 8 bits por canal, codificados em RGB (vermelho, verde e azul). Essa estruturação típica é diferente quando se trata da maioria dos tipos de imagens médicas, cujos “canais” representam simplesmente uma medida física, tal como a densidade radiográfica. A resolução de contraste, nesse caso, é determinada pela quantidade de tons de cinza que são representados na imagem. Nesse caso, numa codificação de 8 bits, a quantidade total de tons varia numa escala de 0 a 255, convencionando-se 0 como preto e 255 como o branco máximo. Ainda assim, equipamentos mais avançados, desde os anos 2000, ao menos, convertem a variação de tons reais de cinza em escalas com ainda maior sensibilidade, em resoluções de contraste de 10, 12 e, atualmente, até 16 bits (1.024, 4.096 ou mais de 65 mil níveis diferentes de cinza, respectivamente).

Outro fator de resolução, chamado resolução espacial, também determina diferenças de características na imagem digital. Nesse caso, o relacionado ao menor tamanho de elemento da imagem como um todo, ou seja, o pixel. Quanto menor o tamanho do pixel de uma imagem digital, maior a quantidade de detalhes que podem ser representados da projeção do objeto original. Isso também determina o tamanho da matriz que representa essa imagem digital. Uma resolução espacial de 200 μm numa imagem cujo tamanho é de 30 \times 40 cm indica que a matriz espacial a ser formada na imagem digital terá 1.500 \times 2.000 pixels. Se cada pixel dessa matriz tiver uma resolução de contraste de 10 bits, por exemplo, isso significa então que o arquivo digital relativo a essa imagem terá 1.500 \times 2.000 \times 10 = 30 M bits, ou seja, ocupará 3,75 Mbytes de espaço de memória. O que mostra que, quanto mais refinada for a resolução (tanto espacial, representada como um valor cada vez menor de pixel, como de contraste, representada como um valor cada vez maior de bits, ou tons de cinza) da imagem digital, maior é o espaço necessário de armazenamento dos bits que a representam.

2.2. Imagem *Raw* e Imagem Processada

Nesse contexto, uma abordagem importante a ser considerada nos atuais processos de aquisição da imagem médica digital pelos diversos tipos de equipamentos da área de diagnóstico por imagem é a relação entre o que se chama imagem *raw* e imagem processada (ou pós-processada, como alguns chamam). E aqui, o que se chama de processamento de imagem ganha uma nova semântica, ainda que inserido tecnicamente nos conceitos apresentados adiante.

Imagem *raw* (ou crua, na tradução literal) é aquela que não foi submetida a qualquer tipo de processamento digital (também chamada de imagem *para* processamento). Na aquisição, por exemplo, de imagem médica por exposição a equipamento de raios X, a imagem *raw* é obtida diretamente dos dados de atenuação do feixe de raios X. Apresenta uma escala linear entre o log da exposição e a densidade óptica, além de menor contraste e uma região maior de captura (Figura 1). O alcance da radiação é muito amplo e torna-se difícil para o olho humano captar muitas

das informações de diferenças de contraste necessárias para a adequada interpretação. Trata-se de aspecto associado ao fato de que a resposta do olho humano à variação de contraste é logarítmica¹.

A partir do processo físico de aquisição que gera a imagem *raw*, obtém-se a chamada imagem processada que, na verdade, é a imagem “para apresentação” (ao médico). Trata-se da imagem final a partir da qual será feita a análise diagnóstica e que corresponde a um arquivo digital resultante da aplicação de alguma(s) técnica(s) de processamento digital sobre a imagem *raw*. A finalidade é deixar essa imagem a mais próxima possível da que seria obtida com filme, por exemplo, ou para evidenciar uma área de interesse. As suas características dependem da(s) técnica(s) utilizada(s), variando de acordo com o equipamento e a versão do software, e com um detalhe importante: são intrinsecamente dependentes do fabricante do equipamento/sistema de aquisição. Apesar disso, em geral, os algoritmos de processamento utilizados atuam para modificar/adaptar a curva de atenuação dos raios X.

A qualidade da imagem *raw* é dependente do detector utilizado na aquisição da imagem. Ela geralmente está estruturada em resolução de contraste de 14 bits por pixel (enquanto as processadas apresentam 12 bits). Mas, apesar de ser a processada a que é apresentada ao médico para a avaliação diagnóstica, é na imagem *raw* que deve ser realizada qualquer avaliação de qualidade do processo de aquisição para evitar a diferença da utilização de diferentes métodos de processamento (Figura 2).

A diversidade de métodos de processamento torna difícil a comparação entre imagens. Na transformação da imagem *raw* para a processada ocorrem dois tipos de processamento: pré-processamento: usado para correções mais básicas da imagem, como pixels defeituosos; e pós-processamento: utilizado para melhorar a apresentação da imagem, com o uso de técnicas para diminuição do ruído e aumento de contraste³.

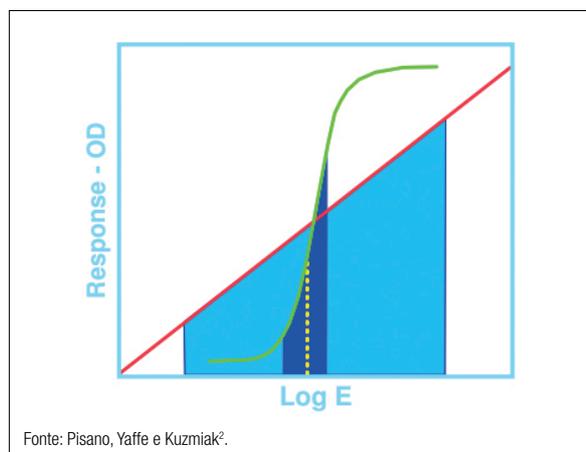


Figura 1. Comparação entre a resposta de densidade óptica (*response* - OD) e exposição para o filme mamográfico e a mamografia digital.

2.3. Ruído em Imagens

Os processos de aquisição de imagem geralmente são afetados pelo ruído devido à instrumentação e a erros de transmissão e compressão⁴. O ruído geralmente é quantificado pela porcentagem de sinais que estão corrompidos e os tipos mais comuns em imagens por raios X, por exemplo, são: quântico, gaussiano e Rayleigh.

Em mamografia, por exemplo, o ruído quântico é o principal encontrado nas imagens⁵; ele é resultado da variação no número de fótons de raios X absorvidos pelo detector em determinado intervalo de tempo e possui relação proporcionalmente inversa com a dose recebida pelo paciente⁶. Esse ruído reduz o contraste entre o fundo da imagem e estruturas de interesse, dificultando a detecção de pequenos detalhes ou sinais⁷. Recentes estudos mostraram que o ruído quântico é determinante na qualidade da imagem, de modo que acaba tendo influência direta no desempenho do médico radiologista na detecção precoce de algum achado. Esse ruído também exerce uma influência maior do que a resolução espacial da imagem na detecção de microcalcificações e na classificação de nódulos⁸.

O ruído gaussiano obedece a uma distribuição gaussiana ou normal dos seus valores de amplitude ao longo do tempo⁹. Ao analisar essa distribuição, tem-se que o ruído é aleatório, pois há uma variação aleatória no valor dos pixels da imagem para mais e para menos, que ocorre em todos os pixels sem diferenciar partes da imagem nem variar com o tempo. Logo, quando encontrado na imagem, modifica os valores de intensidade dos pixels e, com isso, alguns detalhes do sinal são perdidos. Esse tipo de ruído causa perda de nitidez nas bordas e em regiões planas. Também se verifica distorção dos tons de cinza e do brilho da imagem¹⁰.

3. Pré-Processamento das Imagens

As imagens médicas digitais geralmente não são adequadas para a visualização direta, sem qualquer tipo de processamento. Usualmente, há necessidade de realizar um pré-processamento da imagem para que ela seja corrigida ou realçada adequadamente, melhorando o seu contraste,

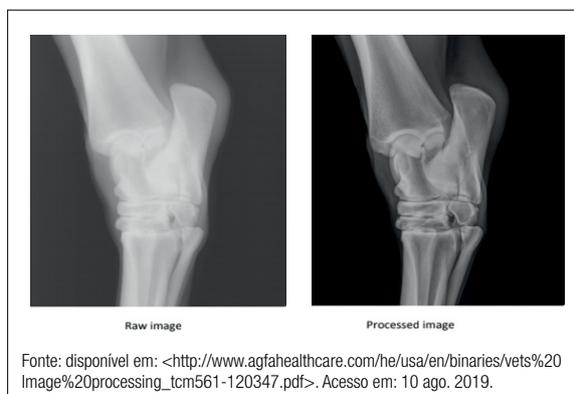


Figura 2. Comparativo entre imagens *raw* e processada.

corrigindo pixels defeituosos, reduzindo ruído ou permitindo que técnicas avançadas de processamento sejam mais eficientes.

As técnicas de processamento que alteram o contraste das imagens podem destacar determinados objetos do fundo da imagem e possibilitar melhor percepção visual, baseada em critérios subjetivos do olho humano.

As técnicas de realce de contraste podem ser classificadas em diretas e indiretas. Nas técnicas diretas, também chamadas operações ponto a ponto, é estabelecido um critério de medida de contraste aplicado diretamente aos valores dos pixels da imagem. Ao contrário, nas técnicas indiretas é realizada uma operação sobre o histograma dos níveis de cinza da imagem, para depois alterar o contraste¹¹.

Um dos exemplos de técnicas diretas de realce de contraste é a transformada *wavelet*. Transformadas *wavelet* vêm sendo largamente empregadas em diferentes aplicações nas últimas décadas, principalmente nas áreas de processamento de sinais e de imagens, possibilitando a representação de imagens multiescala¹²⁻¹⁴. As vantagens da transformada *wavelet* se concentram no fato desse tipo de transformada poder ser usada para decompor o sinal em diferentes escalas, tanto no domínio da frequência quanto no domínio do tempo. Ela é capaz de escolher a escala apropriada no domínio da transformada *wavelet*, ignorando ou reduzindo a contribuição de outras escalas.

Alguns algoritmos que utilizam transformadas *wavelet* vêm sendo implementados para realce de contraste na literatura¹⁵⁻¹⁷.

Uma técnica indireta básica de realce de contraste é a equalização de histograma (*histogram equalization* — HE). Essa técnica mapeia a entrada de níveis de cinza para um nível de cinza proporcional à sua densidade cumulativa, de forma que a probabilidade de cada nível de cinza da imagem resultante (pós-HE) seja uniformemente distribuída. Idealmente, a imagem de saída deve conter a mesma quantidade de pixels para cada valor discreto de nível de cinza. Em algumas situações, a equalização de histograma resulta em um excessivo realce de contraste, podendo produzir ruídos na imagem¹⁸.

Na equalização global, todos os níveis de cinza da imagem são levados em consideração no processamento. Já nas equalizações em regiões, é definida uma janela para varrer a imagem de forma pontual ou em blocos. Na equalização regional pontual, apenas o ponto central da imagem é equalizado, enquanto na equalização por blocos, isso ocorre com todos os pontos da janela.

Uma das variações da HE que consideram a equalização por blocos é a equalização adaptativa de histograma com limitação de contraste (CLAHE), desenvolvida por Pizer et al.¹⁹. Essa técnica ajusta o histograma original a um histograma pré-definido e depois redistribui os valores excedentes em outras intensidades, ou seja, aqueles que não se encaixaram na distribuição, antes de computar a função de distribuição cumulativa²⁰.

A filtragem é uma das técnicas mais utilizadas no pré ou pós-processamento digital de imagens. Entende-se filtragem

como a operação realizada para remover ou reduzir um componente indesejado da imagem, como o ruído, ou para melhorar ou extrair um conjunto particular de elementos da imagem, como as suas bordas. A operação de filtragem pode ser realizada tanto no domínio espacial como no domínio da frequência. Alguns filtros têm equivalentes nos dois domínios. Por outro lado, alguns filtros operam exclusivamente em um dos domínios.

A maioria das imagens com as quais estamos familiarizados é representada no domínio espacial, por uma matriz de intensidade de cor ou de escala de cinza, em um espaço bidimensional. As imagens no domínio espacial são amostradas discretamente a partir da intensidade de um sinal no espaço, havendo uma correspondência direta entre as coordenadas da imagem e o espaço no “mundo real”.

Na área de processamento digital de imagens, frequentemente utiliza-se o termo frequência para descrever a taxa de mudança de um sinal no espaço, por exemplo, a taxa na qual a intensidade do pixel muda, à medida que se percorre uma imagem. Nesse contexto, a representação da imagem é realizada no chamado domínio da frequência espacial.

O conceito de frequência espacial é extremamente útil no processamento de imagens. Muitos dos métodos utilizados no processamento de sinais analógicos e digitais (sinais frequentemente descritos pela sua frequência temporal) têm equivalentes diretos no processamento de imagens.

A taxa de mudança de intensidade em uma imagem pode ser representada em termos de um perfil de intensidade senoidal, que pode ser descrito como a soma de uma série de senoides de frequência espacial e amplitude específicas. Assim, qualquer imagem pode ser descrita como a soma de uma série de senoides nas direções x e y . Essa operação pode ser descrita através da transformada de Fourier (TF).

Em processamento de imagens, a TF bidimensional converte uma imagem no domínio espacial para o seu equivalente no domínio de frequência espacial. Nessa operação, os valores de intensidade reais da imagem são convertidos em uma matriz complexa simétrica no domínio da frequência. Assim, a TF de uma imagem é sua representação exata, na qual nenhuma informação é perdida no processo de transformação.

O espectro de Fourier de uma imagem digital é uma representação da magnitude do domínio da frequência espacial dos dados da imagem. As coordenadas da matriz do espectro representam diferenças na frequência espacial. Por convenção, os espectros 2D de Fourier são exibidos com os termos de frequência espacial mais baixa no centro, também chamados de frequência zero ou termo DC (do inglês *direct current*). A magnitude ou amplitude do termo DC representa a intensidade média de pixels da imagem no domínio espacial. Como a amplitude do termo DC é normalmente muito maior do que a amplitude das frequências diferentes de 0, é usual exibir o logaritmo das amplitudes no espectro de Fourier.

A Figura 3 mostra alguns exemplos de imagens no domínio espacial (à esquerda) e seu respectivo espectro de

Fourier (à direita). Linhas e bordas pontiagudas em imagens são caracterizadas por amplitudes diferentes de zero com altas frequências espaciais. As linhas retas e bordas nas imagens dão origem a estruturas lineares no espectro de Fourier, e essas estruturas estão perpendiculares às suas linhas de origem da imagem no domínio espacial.

A maior parte dos programas de processamento de imagem opera exclusivamente no domínio espacial. No entanto, existem operações que são mais rápidas e precisas após transformar a imagem do domínio espacial para o domínio da frequência. Por outro lado, existem algumas operações que só podem ser realizadas no domínio da frequência espacial. As imagens por ressonância magnética (MRI), por exemplo, são adquiridas diretamente no domínio da frequência espacial (chamado espaço k), sendo convertidas para o domínio espacial posteriormente, para criar uma imagem anatômica interpretável.

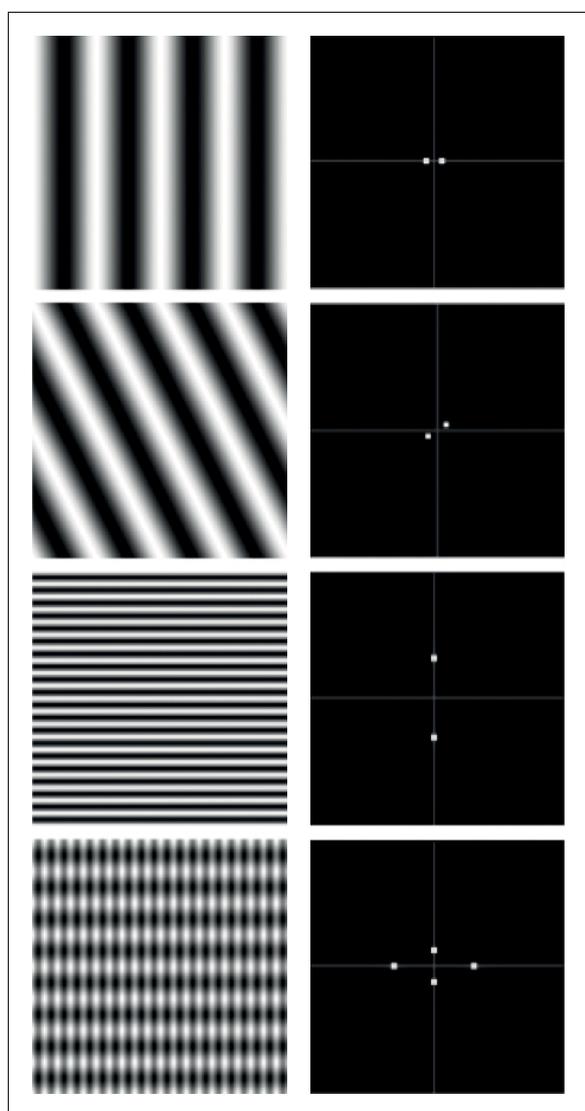


Figura 3. Imagens no domínio espacial (coluna à esquerda) e seus respectivos espectros de Fourier (coluna à direita).

Uma filtragem no domínio espacial é realizada através de uma operação que mapeia os valores dos pixels para novos valores, considerando a vizinhança dos pixels, utilizando uma máscara (ou *kernel*). As dimensões da máscara, em pixels, definem a vizinhança que será considerada na operação e, conseqüentemente, o quanto a filtragem operará sobre a imagem original.

Uma das implementações mais simples de uma filtragem espacial é o filtro de suavização (*blurring/smoothing filter*), no qual a intensidade original de cada pixel é substituída pela média ou mediana dos pixels da vizinhança. A dimensão dessa vizinhança pode ser bem próxima, como 3×3 pixels ao redor do pixel no qual será realizada a operação. Esse processo de cálculo da média ou mediana produz uma nova imagem com variabilidade reduzida nas intensidades, ou seja, é uma versão suavizada da imagem original. Convencionalmente, os elementos da máscara são inteiros positivos ou negativos e o resultado é dividido pela soma de todos os elementos. Outro filtro espacial bastante usual é aquele cujos elementos são uma versão discreta de uma função gaussiana, que produz uma suavização de imagens ruidosas.

Os filtros de suavização ou borrimento são chamados filtros passa-baixa, porque atenuam frequências espaciais altas e deixam passar as frequências espaciais baixas.

Existem filtros cujo objetivo é realçar a imagem, destacando as transições entre diferentes intensidades da imagem. Nesse caso, os filtros são chamados de passa-alta, pois atenuam frequências espaciais baixas e deixam passar as frequências espaciais altas.

Enquanto os filtros de suavização assemelham-se a um processo de "integração" da imagem, os filtros de realce atuam de forma semelhante a uma operação de "derivação", realizando operações de diferenças entre os valores de intensidade dos pixels, dando destaque a bordas e mudanças abruptas de intensidade.

Existe uma variedade de filtros para detecção de bordas, como Sobel, Prewitt e Laplaciano (2^{a} derivada), entre outros²¹. Um dos métodos de detecção de bordas mais utilizados é denominado de filtro de Canny, que possui dois passos, sendo a imagem inicialmente suavizada utilizando um filtro gaussiano, seguido da aplicação de um filtro derivativo de primeira ordem, como Sobel ou Prewitt, para evidenciar regiões da imagem com alto gradiente²². A detecção de bordas é bem adequada para a segmentação de estruturas com diferentes contrastes em diferentes regiões, como ossos. No entanto, alterações no valor de cinza local induzidas por ruído e artefatos (de metal) são muitas vezes erroneamente identificadas como bordas. Também deve-se notar que, sem processamento adicional, os métodos de detecção de bordas não segmentam necessariamente todos os voxels ósseos na imagem e, portanto, precisam ser combinados com outros métodos, como o crescimento da região²³.

Em alguns casos, a filtragem pode ser realizada no domínio de frequência espacial, realizando a multiplicação da TF da imagem pela TF da máscara de convolução, seguida pela

transformação inversa de Fourier, para retornar ao domínio espacial. Essa opção é a escolha preferencial quando são usadas grandes máscaras de convolução, pois o processamento pode ser mais rápido no domínio da frequência.

Deve-se destacar que, em termos matemáticos, o processo descrito anteriormente como convolução é, na realidade, uma correlação. A convolução difere da correlação quando a matriz da máscara é girada 180 graus. A diferença é significativa apenas para as máscaras assimétricas ou quando o processamento está sendo realizado nas imagens *raw*. Assim, a maioria dos textos de processamento de imagens utiliza o termo convolução em vez de correlação.

Em imagens de tomografia computadorizada por raios X (CT) e MRI de cérebro, por exemplo, podem ser utilizados algoritmos de rastreamento de objetos (*object tracking*) para remover valores próximos a 255 na escala de cinza (de 8 bits) para remover da imagem partes do crânio. Filtros de média são utilizados geralmente para remoção de artefatos, assim como máscaras específicas para realçar regiões de interesse e técnicas morfológicas para tratar as imagens sem alterar formatos. A Figura 4 ilustra alguns casos de MRI e CT nas quais essas técnicas foram aplicadas²⁴.

Outros exemplos de aplicações de técnicas de pré-processamento estão na redução de ruídos e correção de pixels defeituosos. O espectro de potência de ruído (NPS) da imagem “corrigida” será igual à potência do ruído da imagem *raw* somado ao das imagens de ganho e de *offset*. Caso a imagem de ganho seja produzida com uma intensidade

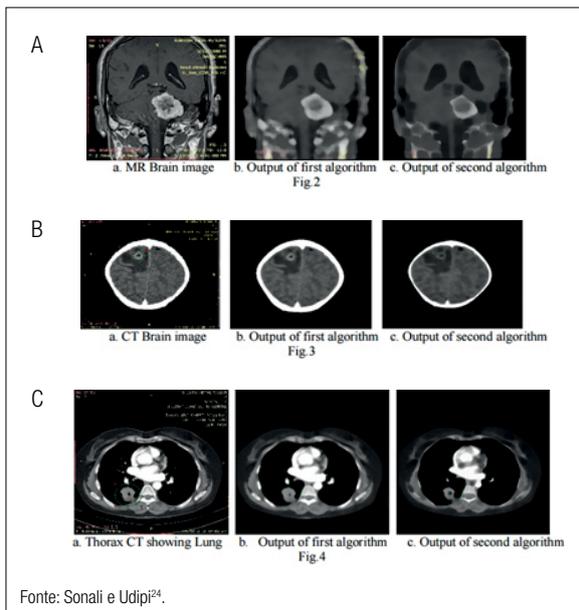


Figura 4. Aplicação de algoritmos de rastreamento como técnicas de pré-processamento em imagens de ressonância magnética e tomografia computadorizada para (A) remoção de partes do crânio; (B) remoção de artefatos; (C) manutenção e realce de tumores.

muito alta, haverá uma degradação da eficiência quântica do detector (DQE)²⁵. A correção de pixels defeituosos é feita usando filtros de média ou mediana, ou também pelo uso de algoritmos de interpolação, como mostra o exemplo na Figura 5.

Como etapas de pós-processamento, várias técnicas podem ser empregadas nesses procedimentos, tais como restauração de contorno²⁶ (Figura 6), equalização periférica²⁷ (Figura 7), melhoria de contraste e brilho por modificação da relação entre os níveis de cinza da imagem original (adaptações na *look-up table* — LUT —, conforme exemplos gráficos na Figura 8).

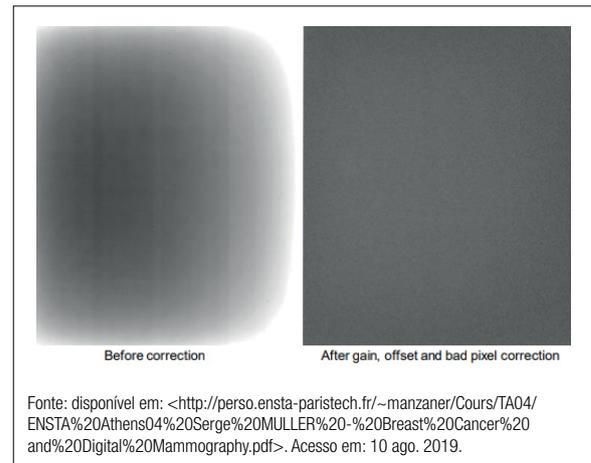


Figura 5. Pré-processamento da imagem para corrigir pixels defeituosos, *offset* e ganho. Exemplos e filtros passa baixa frequência (*low pass*), passa alta frequência (*high pass*) e operações aritméticas.

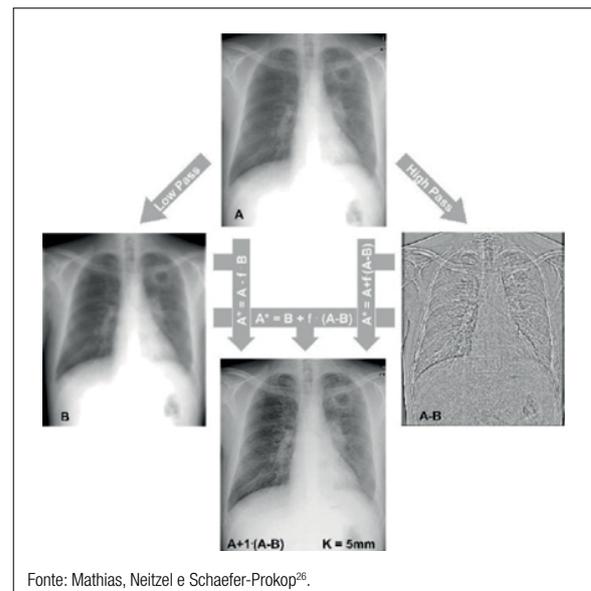


Figura 6. Aumento das bordas tendo como base um filtro de média.

4. Segmentação

O cérebro humano rapidamente reconhece os diferentes objetos numa imagem que está sendo observada pelos olhos, porém, no caso dos sistemas computacionais, para reconhecer os objetos e as estruturas presentes é necessário um algoritmo para analisar a sequência e os valores dos pixels na imagem e só então tomar uma decisão sobre quais objetos realmente estão presentes na imagem. Geralmente essa análise computacional se inicia pela segmentação dos diferentes objetos existentes na imagem.

Assim, na área da saúde, os médicos analisam cuidadosamente as imagens à procura de anormalidades, ou regiões de interesse, um processo cansativo e que pode levar muito tempo. Quando o médico encontra uma região com suspeita de anormalidades, ele se concentra nessa região, examinando suas características, procurando por padrões para decidir se de fato a imagem demonstra algum sinal particular de possível doença no paciente.

A segmentação pode ser definida como o processo de separação das imagens em regiões com características estruturais similares. Os atributos mais básicos para a segmentação numa imagem são a amplitude da luminância do pixel, as bordas e texturas.

As técnicas de segmentação de imagens são responsáveis pela divisão das imagens em regiões de interesse para

que, então, seja feita a classificação ou o reconhecimento dos objetos presentes na imagem²⁸. A segmentação é considerada uma das tarefas mais difíceis no processamento de imagens, no qual a precisão da segmentação determina o sucesso ou o fracasso dos processos subsequentes de análise computadorizada, classificação e reconhecimento de padrões²⁹.

Como não existe uma única técnica de segmentação de imagens, surgiram vários algoritmos, tais como a limiarização, aplicável em imagens que possuam valores de intensidade de pixel que possam ser agrupados em dois ou mais grupos; ou mesmo a técnica de agrupamento que, baseada em medidas de atributos extraídos da imagem (como média móvel, desvio padrão, moda), faz o agrupamento de pixels que tenham atributos similares; e também técnicas baseadas em detecção de bordas, que procuram por variações abruptas de intensidade na imagem para segmentar as regiões³⁰.

Na literatura, diversas técnicas de segmentação automática são apresentadas, baseadas desde em algoritmos simples de limiarização^{31,32} até em algoritmos de alta complexidade utilizando redes neurais artificiais e aprendizado de máquina^{33,34}. Basicamente, técnicas de segmentação são divididas em técnicas automáticas e semiautomáticas. As técnicas automáticas não necessitam de interferência do usuário para seleção de região ou de ponto de interesse; já as semiautomáticas geralmente são inicializadas a partir da seleção, pelo usuário, de um ponto ou área de interesse dentro da imagem. Por exemplo, Zhuo et al.³⁵ propuseram, em um recente trabalho sobre segmentação em CT, a combinação de algoritmos de crescimento de região com atributos estatísticos robustos (*robust feature statistics* — RFS), formando assim um algoritmo de segmentação localmente adaptativo baseado em RFS.

Entre os métodos de segmentação automática se destacam alguns algoritmos baseados em crescimento de região³⁶⁻³⁸ por meio de sementes posicionadas sobre o tecido, técnicas de segmentação por limiarização do histograma^{31,32} seguida de transformações morfológicas³⁹ e

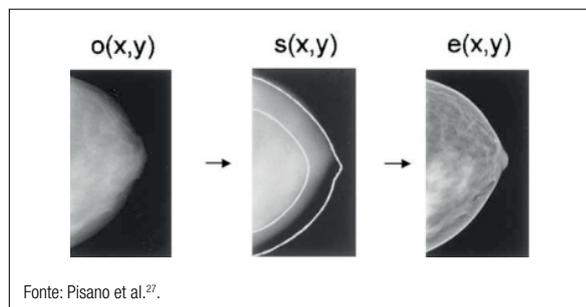


Figura 7. Exemplo de equalização periférica.

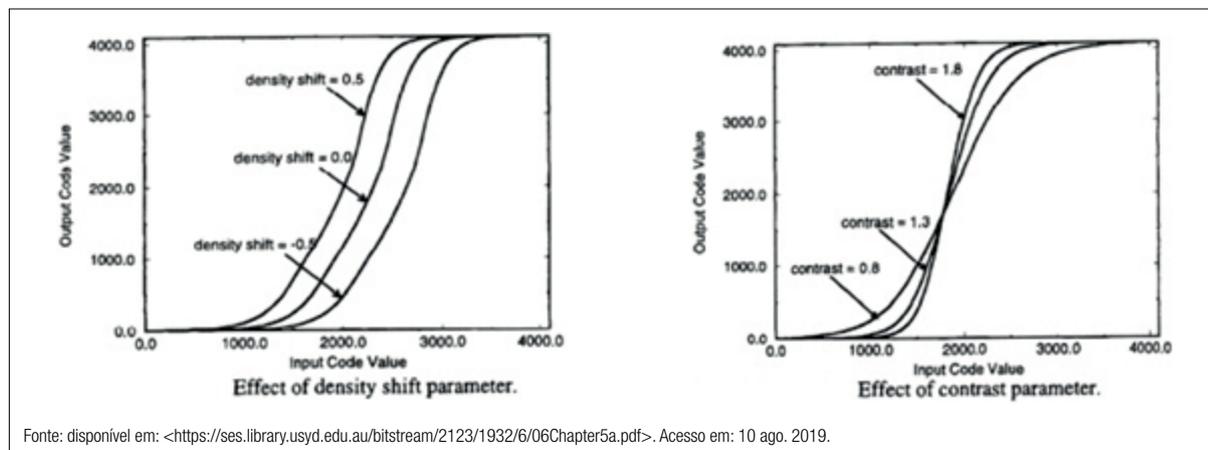


Figura 8. Look-up table em formato de S para as máquinas Kodak.

técnicas de ajuste de atlas morfológicos por meio de transformação afim⁴⁰.

Além dessas, existem as técnicas de segmentação baseadas em região, que utilizam propriedades geométricas para agrupar pixels com propriedades semelhantes, entretanto a eficiência dessas técnicas, na maioria dos algoritmos, é altamente dependente da seleção do ponto de semente (ponto de partida do algoritmo)⁴¹.

A segmentação baseada em região usa conhecimento extraído de uma vizinhança de pixels, através de atributos e das características de pixels (valores de intensidade semelhantes, por exemplo), desde que não sejam bordas, podendo os pixels ser divididos em grupos: divisão e fusão de região, *watershed* e crescimento de região¹⁰.

A técnica de segmentação baseada em divisão e fusão de região inicialmente divide a imagem num conjunto arbitrário de regiões desconexas e, então, realiza a fusão ou uma nova divisão a fim de satisfazer uma condição de segmentação (por exemplo, todos os pixels da região devem possuir o mesmo nível de intensidade), que foi definida previamente.

A forma geral para realizar o procedimento de segmentação pela técnica de divisão/fusão é a seguinte:

- definir a condição inicial de semelhança da região, por exemplo, o desvio padrão da região deve ser maior do que o desvio padrão do fundo;
- assumindo que a imagem é quadrada, subdividir toda a imagem sucessivamente em regiões quadradas (quadrantes) cada vez menores, até que a região seja homogênea;
- fazer iterações do processo de divisão enquanto $Q(R_i) = \text{FALSO}$;
- não sendo possível continuar dividindo as regiões, unir as regiões adjacentes R_j e R_k onde = VERDADE;
- parar quando não for possível realizar mais fusões.

A técnica *watershed* é baseada em conceitos de topografia e hidrografia na qual, considerando uma imagem monocromática, sendo representada em altitude, o pixel de valor alto corresponde a um cume, enquanto um pixel de baixa amplitude corresponde a um vale. Dessa forma, se caísse água sobre essa imagem, os pixels de valores baixos seriam preenchidos pela acumulação da água (chamada de charco ou barragem). Todos os pontos que são preenchidos pelo charco fazem parte da mesma bacia hidrográfica (do inglês *watershed*, que dá o nome a essa técnica), enquanto o cume representa o gradiente máximo em altura dessa superfície.

Há duas formas básicas para calcular computacionalmente as regiões por *watershed* numa imagem, a técnica por *rainfall* e a técnica conhecida por *flooding*. Pelo algoritmo de *rainfall*, os mínimos locais são encontrados em toda a imagem, em cada um desses mínimos é dado um marcador único, e quando são adjacentes locais eles são combinados. Em sequência, em cada pixel não marcado é colocada uma gota de água, que se move para o seu vizinho de menor amplitude até que alcance um pixel marcado, assumindo o valor dessa marcação. Na técnica *flooding*

(inundação), que considera a imagem de entrada visualizada na forma topográfica, a intenção é produzir linhas de divisão de água nessa superfície. A água entra através de furos, feitos em cada mínimo regional, e a amplitude da superfície é reduzida a um grande corpo de água. A água entra pelos orifícios para preencher cada bacia hidrográfica a uma taxa constante. Se a bacia está prestes a transbordar (águas vindas de diferentes mínimos regionais estão prestes a se encontrarem), é construída uma represa conceitual (barreira) sobre a linha do cume em questão, até que a altura seja igual ao ponto mais alto de seu cume. Com a passagem do tempo, são visíveis apenas os topos das barreiras que estão acima do nível da água, que são as linhas correspondentes à *watershed*^{30,42}.

Assim, considerando como uma imagem digital em escala cinza, o menor valor da intensidade de nível de cinza para a imagem é chamado de h_{\min} e o seu maior valor da intensidade de cinza é chamado de h_{\max} . Então, para realizar o cálculo da *watershed* com a teoria de *flooding*, varia-se recursivamente a intensidade de cinza h de h_{\min} até h_{\max} , sendo que as bacias com o mínimo de f são expandidas sucessivamente, sendo X_h a união de um conjunto de bacias pertencentes à mesma intensidade de cinza h . E um componente conectado ao limiar definido como T_{h+1} na intensidade de cinza $h+1$ pode ser um novo mínimo ou uma extensão da bacia X_h , sendo feito o cálculo da zona de influência de X_h sobre T_{h+1} , e a união de todos os mínimos regionais da intensidade de cinza h é denominada de MIN_h .

A técnica de crescimento de região agrupa os pixels numa região, iniciando no pixel de semente (ou pequeno conjunto de pixels) e crescendo espacialmente a partir da verificação da conectividade de pixels segundo o critério de similaridade^{28,29}. Considerando que R seja uma representação espacial da imagem, a segmentação pode ser considerada como sendo a divisão de R em n sub-regiões (R_1, R_2, \dots, R_n). E se realizada, essa união deve resultar em R , ou seja, todo pixel deve pertencer a uma região^{10,28}.

Um algoritmo genérico para o crescimento de região baseado em agrupamento de pixels similares pode ser descrito da seguinte maneira^{10,28}:

- inicie com o ponto de semente (ou um conjunto de pixels);
- acrescente os pixels que possuem propriedades semelhantes (nível de cinza, cor) ao ponto de semente verificando vizinhança 4-conectados ou 8-conectados;
- pare quando não houver mais pixels semelhantes na vizinhança (4-conectados ou 8-conectados).

O resultado desse algoritmo é altamente dependente do local de lançamento do ponto de semente e também da medida ou métrica de similaridade entre pixels utilizada. A forma de medir a similaridade é através da escolha de um valor de limite máximo da diferença absoluta entre o valor de intensidade do ponto de semente e o valor da intensidade do pixel que está sendo analisado no momento^{28,29}.

Outro modo de medir a similaridade é através da comparação com a técnica conhecida por nível de tolerância

aditiva (*additive tolerance level*), que permite variação entre as diferenças absolutas dos níveis de cinza da vizinhança. Para isso, utiliza-se a média de intensidade de pixels da região, ao invés de utilizar somente o valor de intensidade do ponto de semente para realizar a comparação. Sendo T o nível de tolerância admitido (ou seja, compreende a máxima variação de intensidade entre pixels vizinhos admitida), $f(m, n)$ o valor do pixel da imagem na posição (m, n) , R_c a média da região R_c , N_c a quantidade de pixels presentes na região R_c a equação que representa a comparação para o nível de tolerância^{28,29}.

5. Descrição de Imagens

Depois de uma imagem ter sido segmentada em regiões de interesse, é necessário representar e descrever cada região para posterior processamento e análise das imagens.

Imagens médicas armazenam informações complexas e obter as informações mais relevantes é um grande esforço do ponto de vista computacional. Assim, um dos principais desafios da área de análise de imagens é como extrair automaticamente atributos ou características das imagens capazes de descrever sua “essência”.

A representação de uma imagem digital envolve a escolha de elementos de uma região que possam ser utilizados para representá-la, existindo duas alternativas, que podem ser utilizadas simultaneamente: a representação da região através de suas características externas, por exemplo o formato da região, obtida através de atributos extraídos de seus contornos; e a representação da região através das suas características internas, tais como as propriedades dos pixels que compõem a região, como a média dos tons de cinza ou atributos de textura.

Depois de escolher uma representação para a região da imagem, essa representação deve ser descrita com base em características, atributos ou descritores, tais como o comprimento do contorno ou a intensidade média dos pixels da região. Os descritores preferencialmente devem ser invariantes a mudanças de posição, de escala e de rotação da região.

Os métodos existentes na literatura para descrever a forma de um objeto são diversos. Uma sequência de coordenadas cartesianas é um exemplo de descrição de forma quando se está analisando formas biológicas e não há um número suficiente de marcos anatômicos identificáveis na imagem. Os formatos também podem ser descritos pelos momentos angulares, momentos invariantes de Hu, coeficientes gerados pelas transformadas *wavelets*, entre outros⁴³⁻⁴⁵.

Outra maneira de descrever a região de uma imagem é através de sua textura. A textura é definida como uma combinação entre magnitude e frequência da variação de níveis de cinza em uma imagem. Apesar de a intensidade de níveis de cinza e a textura serem independentes, uma está intrinsecamente ligada à outra, isto é, quando uma

pequena área de uma imagem tem muita variação de níveis de cinza, a propriedade dominante é a textura^{43,44}.

A textura pode ser caracterizada por três componentes: contraste local, orientação e escala. O primeiro é a diferença de níveis de cinza entre áreas vizinhas mais claras e mais escuras. Imagens com áreas de alto contraste local possuem textura rugosa, já o contrário, isto é, baixo contraste local, significa textura mais lisa. A orientação está relacionada à disposição da direção dessas áreas mais claras ou mais escuras. Já a escala pode ser definida como a dimensão das áreas de uma imagem, resultando em texturas finas e grossas, dependentes dos tamanhos das áreas claras ou escuras⁴⁶.

Segundo Gonzalez e Woods²⁹, a textura possui três abordagens principais em processamento de imagens:

- abordagem espectral: baseada em propriedades do espectro de Fourier, utilizada principalmente na detecção de periodicidade global, identificando picos de alta energia no espectro;
- abordagem estatística: nesse caso a textura é definida por um conjunto de medidas locais extraídas do padrão;
- abordagem estrutural: baseada na ideia de que as texturas são compostas de primitivas dispostas de forma regular e repetitiva.

Haralick et al.⁴³ caracterizam textura em uma imagem com 14 descritores a partir da matriz de co-ocorrência de níveis de cinza (*spatial gray-level dependence — SGLD*), calculando a probabilidade de ocorrência combinada de direção e distância entre pares de pixels com valores de intensidade semelhantes. A matriz de co-ocorrência SGLD é uma matriz quadrada de tamanho igual à quantidade de níveis de cinza da imagem a ser analisada.

6. Análise e Reconhecimento de Padrões

O desenvolvimento de algoritmos para análise de imagens médicas exige que seja extraído um conjunto de descritores representativos das regiões das imagens. Essa tarefa envolve um alto nível de abstração e continua sendo um desafio para os pesquisadores da área. Métodos matemáticos, estatísticos e computacionais que visam extrair informações específicas de imagens vêm sendo adaptados para essa função, mas tais algoritmos costumam ser bastante específicos para cada tarefa de análise de imagens.

Na área médica, técnicas de reconhecimento de padrões desenvolvidas pela ciência da computação são utilizadas para reconhecimento de tumores, quantificação de deformidades em estruturas anatômicas, visualização de contornos, análises morfométricas e para auxílio ao diagnóstico, entre outras funções.

Para imagens mamográficas, por exemplo, no caso da extração de atributos de microcalcificações e de nódulos, é preciso obter informações que possibilitem a identificação da malignidade ou não (ou ainda quantificar a suspeita). Por isso, atributos geométricos ou morfológicos são

relevantes, uma vez que as medidas de área, perímetro, compacidade, irregularidade, momentos, entre outras, são significativas para associação das estruturas entre lesões malignas ou benignas.

6.1. Seleção de Atributos

Após a extração de atributos das imagens, é preciso selecionar quais são mais significativos, permitindo assim separar os objetos em classes. O processo de seleção de atributos tem como função mapear as medidas extraídas das imagens em características mais significativas²⁹.

A principal finalidade da seleção de atributos é a redução da dimensão dos dados. Isso significa dizer que os métodos de seleção de atributos produzem um conjunto reduzido de dados a serem analisados. As grandes vantagens dessa redução de variáveis são a remoção de características irrelevantes ou redundantes, a visualização gráfica do novo conjunto de atributos e produzir uma representação mais estável, melhorando o desempenho do classificador.

Basicamente, manter a dimensionalidade dos dados como a menor possível é importante, principalmente devido ao menor custo computacional (menor uso de memória e classificador mais rápido) e à maior acurácia do classificador. Entretanto, em alguns casos, uma redução muito acentuada do número de atributos analisados pode reduzir o desempenho do classificador, em virtude de uma perda na capacidade de discriminação dos dados.

Um método bastante usado para a redução da dimensionalidade de variáveis, usado na redução de atributos em imagens, é a análise dos componentes principais (PCA). Para a análise de um conjunto de p variáveis é necessário transformar o conjunto de variáveis originais em um novo conjunto de variáveis não correlacionadas, denominadas de componentes principais. Essas novas variáveis são combinações lineares das variáveis originais e são deduzidas em ordem decrescente de importância, de maneira que o primeiro componente tenha o máximo possível da variação dos dados principais. A PCA é a técnica para encontrar essa transformação. O objetivo é verificar se alguns componentes podem representar a maior parte da variação dos dados originais. Se isso realmente é conseguido, então a dimensionalidade do problema é menor do que p , o número original de variáveis. Com isso, é possível compreender a estruturação e a variação dos dados, permitindo a visualização do problema com um número menor de variáveis.

6.2. Classificação de Padrões em Imagens

Depois que a imagem é processada, com os objetos de interesse identificados e caracterizados através dos descritores mais significativos, um algoritmo de classificação deve ser usado para associar ou classificar os padrões nas imagens. Esse procedimento pode ser feito por meio de classificadores supervisionados ou não supervisionados, ou ainda pelo uso de técnicas híbridas, que utilizam um pouco de cada uma das técnicas para uma classificação final e mais refinada. A escolha da técnica de classificação é talvez a etapa mais complicada de um sistema de reconhecimento

de padrões aplicado em medicina, bem como, em muitos casos, a definição do número de classes nas quais estarão categorizados os objetos de interesse.

Um trabalho desenvolvido em 2001 por Kononenko mostra uma aplicação de aprendizagem de máquinas no diagnóstico médico⁴⁷, no qual se comparam alguns métodos de aprendizagem de máquina, incluindo redes neurais artificiais (RNA), classificadores bayesianos simples e algumas variações e extensões do método e métodos de aprendizado simbólico.

Segundo Kononenko⁴⁷, para um sistema de aprendizado de máquinas ser usado para resolver problemas em diagnóstico médico, ele deve apresentar as seguintes características:

- bom desempenho: o algoritmo tem que ser capaz de extrair informações significativas para avaliação dos dados;
- tratamento de dados errados: muitos dados médicos apresentam erros e ruídos, e algoritmos de aprendizado de máquinas aplicados à área médica devem apresentar medidas efetivas para trabalhar ruídos;
- transparência do conhecimento do diagnóstico: generalização do conhecimento e explicação da decisão deveria ser transparente para os médicos, de modo que possam analisar o conhecimento generalizado e observar os pontos de vista dados no problema de maneira explícita pelo algoritmo, que muitas vezes não poderiam ter sido observados anteriormente;
- capacidade de explicação: o sistema deve ser capaz de explicar a decisão quando do diagnóstico de um novo paciente. Quando o médico se depara com um resultado inesperado, poderá requerer uma explicação de maneira que lhe sirva de sugestão na tomada de decisão do diagnóstico final;
- redução do número de exames: na prática médica, a coleção de dados de pacientes é cara, consome muito tempo e espaço e é prejudicial aos pacientes; então é interessante um classificador que ajude a prever o diagnóstico com um número menor de informações sobre o paciente. Assim, a seleção do subconjunto de atributos para redução do tempo de processamento e verificação dos mais significativos é um ponto essencial em algoritmos de aprendizagem de máquinas.

7. Auxílio Computadorizado ao Diagnóstico

Alguns métodos de segmentação de imagem, para seleção de regiões de interesse ou para realçar e retirar estruturas de interesse em função do tipo de órgão presente, são comumente empregados em etapas ou módulos de processamento específicos, disponibilizados pelos fabricantes nas estações de trabalho (*workstations*) dos equipamentos de imagem, proporcionando aos médicos recursos adicionais para a análise da imagem.

Por exemplo, para a visualização apenas dos ossos ou do tecido pulmonar em imagens de CT, usualmente

existem ferramentas que utilizam técnicas de limiarização (*thresholding*) e janelamento das imagens⁴⁸ (como no exemplo da Figura 9).

Outras ferramentas computacionais mais sofisticadas, os denominados esquemas automáticos ou sistemas semiautomáticos de auxílio computadorizado ao diagnóstico, vêm sendo disponibilizadas para os médicos. Resultantes de

pesquisas e desenvolvimentos da área de processamento de imagens digitais, elas ganharam corpo e representam um recurso importante, sobretudo no campo do diagnóstico por imagem. Denominados, na maioria dos casos, como “esquemas CAD” (da expressão em inglês *computer-aided diagnosis*), espalharam-se a partir das áreas específicas de mamografia e pneumologia para as mais variadas aplicações do radiodiagnóstico (não apenas para imagens obtidas por exposição aos raios X, mas incluídas as produzidas por ultrassom, MRI e em medicina nuclear) e também na odontologia. Por essa razão, essa seção traz uma breve abordagem do que esses esquemas computacionais representam no contexto do processamento de imagens médicas e exemplos ilustrativos de sua aplicação nesse campo.

7.1. Conceitos Básicos dos Esquemas Computed-Aided Diagnosis (CAD)

Ainda que a ideia da criação do CAD date de 1967, como aplicação de auxílio ao diagnóstico em mamografia, no qual computadores indicariam regiões mamárias com anormalidades, até a década de 1980 esses esquemas tinham baixa acurácia em comparação à interpretação dos médicos radiologistas. Como a miniaturização dos componentes computacionais permitiu avanços mais significativos no *hardware* desses sistemas a partir da década de 1990, técnicas mais avançadas de processamento de imagens começaram a ser implantadas, permitindo obter resultados um pouco mais consistentes nessa área. Nas últimas décadas houve um aprimoramento considerável dessa ferramenta, de modo que tais esquemas passaram a ser usados em outras áreas da radiologia, com aplicações hoje em CT do pulmão, de cabeça, pescoço e de estruturas ósseas, avaliação cardíaca e de neoplasias de colo de útero e de próstata¹. Como é constituído de processos muitas vezes genéricos, esquemas CAD também podem ser aplicados a diversas formas de diagnóstico por imagem, como na ultrassonografia e na ressonância magnética, além da radiologia clássica, uma vez que a fonte de todo o procedimento é uma imagem digital.

Esquema CAD é a denominação genérica de um sistema computacional de auxílio ao diagnóstico, conforme proposta originalmente no fim dos anos 1980⁴⁹. Atualmente, a denominação se desdobrou em esquemas CADe e CADx, o primeiro referindo-se àqueles que objetivam exclusivamente a detecção de estruturas de interesse clínico (como os sistemas aprovados para uso clínico comercial pela Food and Drug Administration, nos Estados Unidos, em 1998)⁵⁰ e o segundo correspondente aos sistemas que avançam na análise das estruturas detectadas de modo a atingir também a etapa de classificação, fase do chamado processamento de alto nível, auxiliando assim na interpretação dos eventuais achados⁵¹.

Embora haja alguns esquemas comerciais disseminados em diversos países (Estados Unidos, Canadá, Alemanha, França, Grã-Bretanha, Holanda, Bélgica) sendo utilizados em hospitais ou grandes centros radiológicos⁵², no Brasil se desconhece a utilização de sistemas como esse pelos profissionais da radiologia de maneira geral ou mais extensiva.

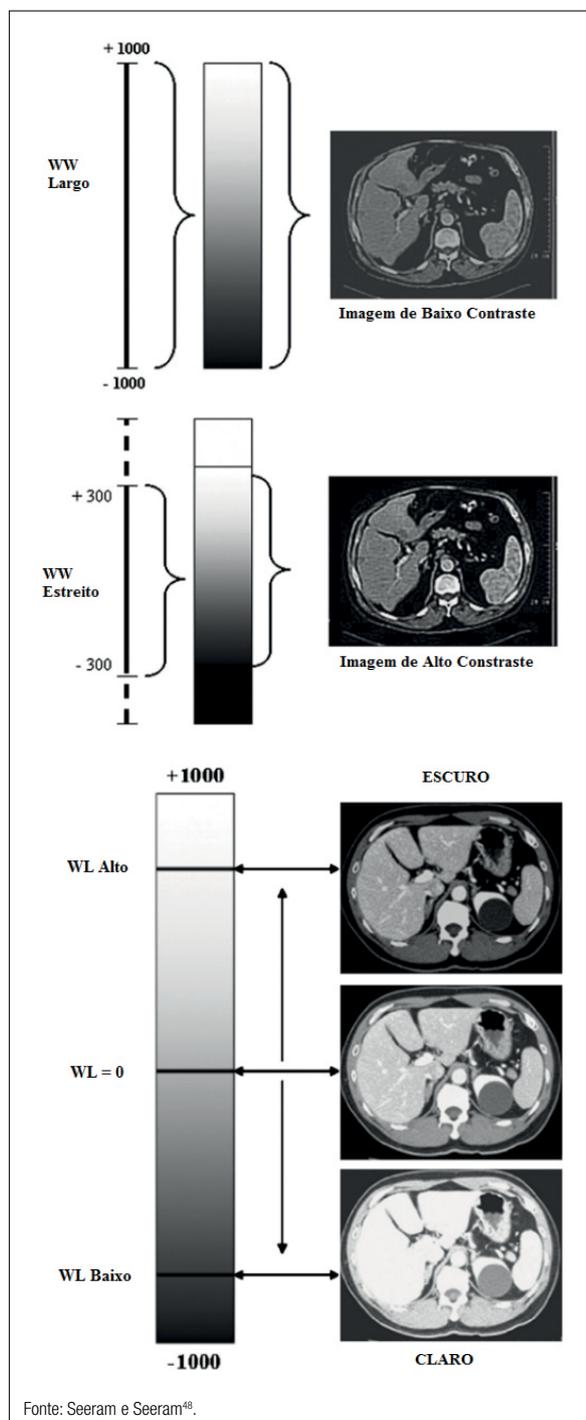


Figura 9. Comparativo entre o tamanho janela (WW: *window width*) e o nível da janela (WL: *window level*).

Apenas têm sido utilizadas algumas ferramentas computacionais disponibilizadas pelos fabricantes de determinados equipamentos de maior porte e custo, como os tomógrafos em geral, ou alguns poucos recursos computacionais embutidos em sistema de aquisição de imagens médicas digitais, como os relacionados à variação de brilho e contraste, seleção de regiões de interesse ou inversão dos níveis de cinza. Certamente, um dos principais motivos está associado ao alto custo desses esquemas em nível comercial, o que reduz drasticamente sua atratividade, ainda mais considerando-se a intrínseca taxa de falsos positivos que se verifica no seu uso⁵³.

7.2. Tecnologias Empregadas

Nishikawa⁵¹ afirma que há cerca de cinco companhias comerciais desenvolvendo sistemas CAD para uso na mamografia. O pesquisador acrescenta que aproximadamente 50% de todas as mamografias realizadas nos Estados Unidos são submetidas ao auxílio do CADe, cujos principais comerciais são: Image CheckerTM, CADVisionTM, VuCompTM, iCADTM, ImagediagnosticTM, M-VisionTM e alguns outros de desenvolvedores japoneses.

No início, sistemas CAD comerciais completos eram dotados de um escâner, geralmente a *laser*, que digitalizava as imagens registradas em película. Um *software* faz uma varredura da imagem digitalizada, destacando qualquer anormalidade que fuja do padrão. Todos os sistemas utilizam algoritmos para identificar e marcar as características que estão associadas a possíveis lesões, demarcando essas regiões na imagem. A seguir, muitas dessas regiões perdem suas demarcações porque a maioria dos sistemas tem limite de número máximo permitido e possível por imagem. Por fim, os sinais demarcados são mostrados num monitor e/ou impressos.

Os detalhes matemáticos dos diferentes tipos de algoritmos existentes nos vários sistemas são sempre extremamente confidenciais, não sendo possível ao usuário alterá-los. Conforme frisam Malich, Fischer e Böttcher⁵⁴, o único sistema que possui um pequeno guia mostrando os algoritmos usados é o Image CheckerTM, fornecendo ao usuário, sem detalhamento, uma ideia de como o sistema funciona.

No entanto, problemas devem ser superados no desenvolvimento do CAD, tais como a variação no contraste das imagens e o pequeno tamanho de algumas estruturas, como diminutas calcificações, difíceis de diferenciar com meros ruídos do sistema. Porém, para o desenvolvimento do esquema para execução do CAD, é preciso que o desenvolvedor tenha conhecimento das áreas que serão analisadas, o que pode representar um obstáculo, uma vez que esse profissional não é da área médica e tem acesso muito restrito a laudos de exames atuais ou de exames anteriormente demarcados, o que pode levar à alta taxa de falsos positivos.

7.3. A Influência do Computed-Aided Diagnosis na Atuação do Médico Radiologista

Desde sua aprovação pela Food and Drug Administration nos Estados Unidos em 1998, a utilização da detecção assistida por computador (CADe) tem se difundido na prática clínica

da mamografia e de outras aplicações de aquisição de imagens médicas, embora verifique-se que seu desempenho é muito influenciado pela quantidade de falsos positivos indicados⁵⁵. Ainda que a quantidade de casos de existência de tumores de mama seja alta e crescente entre os tipos de câncer existentes, é baixa a taxa de casos de malignidade se considerada a população em geral que se submete anualmente a exames mamográficos (estima-se que seja de seis ocorrências a cada mil pacientes submetidas ao rastreamento). E não apenas isso afeta a forma e a persistência no emprego dessa ferramenta como coadjuvante na detecção de lesões suspeitas, mas também o padrão típico de abordagem do profissional médico em função das práticas de cada serviço radiológico. De fato, a prática clínica tem mostrado, por exemplo, que enquanto nos Estados Unidos há tendência de se enfatizar um potencial sinal de anormalidade — como, aliás, normalmente também ocorre no Brasil —, na Grã-Bretanha há mais zelo pela não realização de biópsias que se comprovem desnecessárias⁵⁶.

Porém, muito da eficácia que um esquema desse tipo pode apresentar para auxílio efetivo ao diagnóstico em mamografia passa por um conjunto de fatores⁵⁷, tais como a formação do médico radiologista, sua experiência prévia e número de casos já detectados por ele, a experiência que ele tem com o uso do CAD⁵⁸, a versão e a interatividade do *software* usado e o quanto foram feitas análises comparativas dos exames com e sem o uso do CAD sem que se soubesse o resultado do primeiro. Além, é claro, da qualidade da imagem a ser analisada⁵⁹.

7.4. Influência da Aquisição da Imagem no Desempenho do Esquema Computed-Aided Diagnosis

O desempenho de esquemas CAD pode variar muito dependendo das características das imagens utilizadas nos testes de avaliação^{60,61}. De fato, cada esquema desenvolvido mundo afora utiliza um particular conjunto de imagens e formar uma base de imagens que atenda às diferentes necessidades de diversas técnicas de processamento é uma atividade que demanda trabalho árduo e de difícil consecução, dadas suas peculiaridades. Em mamografia, por exemplo, as imagens precisam obedecer a um conjunto significativo de critérios, desde o processo de aquisição no mamógrafo até sua digitalização, e seria importante que elas fossem provenientes de diferentes lugares para ampliar o universo das características das pacientes⁵⁹.

Uma base de imagens médicas representativa do universo de casos a serem investigados deve apresentar situações que contenham tanto estruturas diversas como aquelas que representam a inexistência de achados. Ela também deve conter uma parcela estatisticamente representativa da população que apresenta as características em investigação. Isso, portanto, implica obter imagens de indivíduos numa larga faixa de idades e com características diversas. Por conseguinte, as imagens são obtidas de diversos equipamentos em diversas instituições e, portanto, sob diferentes condições técnicas. Garante-se, assim, a representatividade estatística de casos, mas a qualidade das imagens

pode ser penalizada, dada a grande heterogeneidade de características relacionadas ao seu processo de aquisição. Isso não apenas impede que se faça a devida comparação de *performance* entre diferentes esquemas CAD, mas pode levar um mesmo esquema a apresentar diferentes performances dependendo do elenco de casos escolhidos, em função de sua origem.

Daí a importância de se conhecer previamente as principais características de qualidade do sistema de aquisição dessas imagens, incluindo o processo de digitalização, a fim de que isso possa guiar até mesmo o desenvolvimento de técnicas de processamento⁶². Assim, a proposição de técnicas de pré-processamento baseadas na eventual perda de qualidade devida ao processo de aquisição/digitalização pode criar uma espécie de “uniformização” da imagem, o que permitiria às etapas de segmentação posteriores atuarem apenas nas características intrínsecas ao órgão de interesse clínico.

Trabalhos prévios^{59,63,64} mostraram que o efeito dos parâmetros relativos à aquisição das imagens na performance do processamento não pode ser negligenciado, em particular quando há problemas de qualidade em relação ao equipamento, verificados em testes de controle de qualidade. Como exemplo prático: na comparação entre os resultados de uma técnica de segmentação⁶² projetada para detectar microcalcificações agrupadas em mamografias digitais aplicada a um conjunto de imagens em duas etapas de testes, foi verificado um aumento em 14% na sensibilidade de detecção (que atingiu um índice de verdadeiros positivos de 95,5%), acompanhado de uma sensível redução da taxa de falsos negativos (de 18,5 para 4,5%) quando o conjunto de imagens foi submetido a um pré-processamento para realçar características a partir do conhecimento de degradações introduzidas no processo de aquisição⁵⁹. Tais técnicas de realce focalizaram essencialmente aspectos relacionados a: tamanho de ponto focal, através do emprego da função de transferência de modulação (FTM); magnificação radiográfica utilizada; ruído, com emprego do espectro de Wiener; e curva característica do digitalizador.

Assim, o ganho já comprovado ao se utilizar características do processo de aquisição para desenvolver técnicas de pré-processamento que “corrijam” as degradações introduzidas por tal processo nas imagens digitais é um aspecto de significativa importância na projeção da necessidade de se estudar o estabelecimento de uma “uniformização” dos conjuntos de imagens de testes dos esquemas CAD. A finalidade seria a técnica de processamento atuar exclusivamente apenas sobre as características do órgão de interesse clínico, para que os diferentes esquemas computacionais existentes possam, inclusive, ser comparados em termos de eficácia.

8. Considerações Finais

A área de pesquisa em processamento e análise de imagens médicas é ilimitada. Centenas de aplicações relacionadas

ao diagnóstico médico e estudo de processos biológicos incorporam o processamento digital de imagens e técnicas de análise. Este artigo apresenta uma abordagem conceitual sobre algumas técnicas de processamento e análise digital de imagens, visando subsidiar suas aplicações na prática clínica e na pesquisa em imagens médicas.

Diversos algoritmos vêm sendo propostos na literatura para cada estágio de processamento de imagens médicas, assim como para solucionar problemas específicos em diferentes modalidades de imagem.

A avaliação de uma imagem médica requer uma análise cuidadosa e compreensão das propriedades e dos detalhes das imagens, que incluem as condições de aquisição, tais como a modalidade de imagem, as condições experimentais, por exemplo a dose de radiação, e as características do indivíduo ou sistema biológico imageado. Portanto, uma abordagem baseada no conhecimento para a análise e interpretação de tais imagens é preferencial em comparação a abordagens analíticas ou estatísticas.

A inovação no diagnóstico por imagens médicas está avançando para a integração de distintas modalidades e avanços técnicos que produzam imagens de maior resolução espacial, temporal e razão sinal-ruído. Aliados aos computadores com maior capacidade de processamento, os métodos de análise de imagens médicas devem avançar no sentido de extrair novas informações que, unidas à mineração de grandes bases de dados e imagens, permitam a combinação de dados multidimensionais, tais como genótipos e estruturas, possibilitando a integração frutífera com a inteligência artificial.

Referências

1. Evans AL. The evaluation of medical images. Bristol: Hilger; 1981.
2. Pisano ED, Yaffe MJ, Kuzmiak CM, eds. Digital mammography. Filadélfia: Lippincott Williams & Wilkins; 2004.
3. Borg M, Badr I, Royle G. Should processed or raw image data be used in mammographic image quality analyses? A comparative study of three full-field digital mammography systems. *Radiat Prot Dosimetry*. 2014;163(1):102-11. <https://doi.org/10.1093/rpd/ncu046>
4. Sinha GR, Neha A. Fuzzy based Image Enhancement Method. *IJCA*; 2015.
5. Yaffe MJ. Digital Mammography. In: Beutel J, Kundel HL, Van Metter RL (eds.). *Handbook of Medical Imaging. Physics and Psychophysics*. Bellingham: SPIE Press; 2000. v. 1. p. 329-372.
6. Dalmazo J, Elias Júnior J, Brocchi MAC, Costa PR, Azevedo-Marques PM. Otimização da dose em exames de rotina em tomografia computadorizada: estudo de viabilidade em um hospital universitário. *Radiol Bras*. 2010;43(4):241-8. <http://dx.doi.org/10.1590/S0100-39842010000400008>
7. Borges LR, Guerrero I, Bakic PR, Maidment ADA, Schiabel H, Vieira MAC. Simulation of dose reduction in digital breast tomosynthesis. In: 13th International Workshop on Breast Imaging; 2016; Malmö. *Anais*. 2016. p. 343-50. http://doi.org/10.1007/978-3-319-41546-8_43
8. Saunders Jr. RS, Baker JA, DeLong DM, Johnson JP, Samei E. Does image quality matter? Impact of resolution and noise on mammographic task performance. *Med Phys*. 2007;34(10):3971-81. <https://doi.org/10.1118/1.2776253>
9. Knoll GF. Radiation detection and measurement. Nova York: John Wiley & Sons; 2010.

10. Leon-Garcia A. Probability, statistics, and random processes for electrical engineering. Upper Saddle River: Pearson; 2017.
11. Akila K, Jayashree LS, Vasuki A. Mammographic image enhancement using indirect contrast enhancement techniques—a comparative study. *Proc Comp Scien*. 2015;47:255-61. <https://doi.org/10.1016/j.procs.2015.03.205>
12. Wickerhauser V, Coifman RR, Meyer Y. Wavelet analysis and signal processing. In: Ruskai MB, Beylkin G, Coifman R, Daubechies I, Mallat S, Meyer Y, and Raphael L, editors. *Wavelets and Their Applications*. Boston: Jones and Bartlett; 1992.
13. Antonini M, Barlaud M, Mathieu P, Daubechies I. Image coding using wavelet transform. *IEEE Trans Image Proc*. 1992;1(2):205-20. <https://doi.org/10.1109/83.136597>
14. Chang RF, Wu WJ, Moon WK, Chen DR. Automatic ultrasound segmentation and morphology based diagnosis of solid breast tumors. *Breast Cancer Res Treat*. 2005;89(2):179-85. <https://doi.org/10.1007/s10549-004-2043-z>
15. Laine AF, Fan J, Schuler S. A framework for contrast enhancement by dyadic wavelet analysis. Nova York: Elsevier; 1994.
16. Heinlein P, Drexler J, Schneider W. Integrated wavelets for enhancement of microcalcifications in digital mammography. *IEEE Trans Med Imag*. 2003;22(3):402-13. <https://doi.org/10.1109/TMI.2003.809632>
17. Scharcanski J, Jung CR. Denoising and enhancing digital mammographic images for visual screening. *Computerized Med Imag Graphics*. 2006;30(4):243-54. <https://doi.org/10.1016/j.compmedimag.2006.05.002>
18. Pisano ED, Gatsonis C, Hendrick E, Yaffe M, Baum JK, Acharyya S, et al. Diagnostic Performance of Digital Versus Film Mammography For Breast-Cancer Screening. *N Engl J Med*. 2005;353(17):1773-83. <https://doi.org/10.1056/NEJMoa052911>
19. Pizer SM, Amburn EP, Austin JD, Cromartie R, Geselowitz A, Greer T, et al. Adaptive histogram equalization and its variations. *Comput Gr Image Process*. 1987;39(3):355-68. [https://doi.org/10.1016/S0734-189X\(87\)80186-X](https://doi.org/10.1016/S0734-189X(87)80186-X)
20. Lu L, Zhou Y, Panetta K, Aghaian S. Comparative study of histogram equalization algorithms for image enhancement. *Mobile Multimedia/Image Processing, Security, and Applications*. Baltimore: SPIE; 2010.
21. Sharma N, Aggarwal LM. Automated medical image segmentation techniques. *J Med Phys*. 2010;35(1):3-14. <https://doi.org/10.4103/0971-6203.58777>
22. Canny J. A Computational Approach to Edge Detection. *IEEE Trans Pattern Anal Mach Intell*. 1986;8(6):679-98.
23. Rathnayaka K, Sahama T, Schuetz MA, Schmutz B. Effects of CT image segmentation methods on the accuracy of long bone 3D reconstructions. *Med Eng Phys*. 2011;33(2):226-33. <https://doi.org/10.1016/j.medengphys.2010.10.002>
24. Sonali P, Udipi VR. Preprocessing To Be Considered For MR and CT Images Containing Tumors. Retrieved. *J Electrical Electron Eng Res [Internet]*. 2012 [acessado em 10 ago. 2019];1(4):54-7. Disponível em: <http://iosrjournals.org/iosr-jeee/Papers/vol1-issue4/G0145457.pdf?id=2706>
25. Moy JP, Bosset B. How does real offset and gain correction affect the DQE in images from x-ray flat detectors? *Med Imag*. 1999;3659. <https://doi.org/10.1117/12.349555>
26. Mathias P, Neitzel U, Schaefer-Prokop C. Principles of image processing in digital chest radiography. *J Thorac Imaging*. 2003;18(3):148-64.
27. Pisano ED, Cole EB, Hemminger BM, Yaffe MJ, Aylward SR, Maidment AD, et al. Image processing algorithms for digital mammography: a pictorial essay. *Radiographics*. 2000;20(5):1479-91. <https://doi.org/10.1148/radiographics.20.5.g00se311479>
28. Rangayyan RM. Biomedical image analysis. Biomedical engineering series. Londres: CRC Press; 2005.
29. Gonzalez RC, Woods RE. *Processamento digital de imagens*. 3ª ed. São Paulo: Pearson Prentice Hall; 2010.
30. Pratt WK. *Digital image processing*. 4ª ed. Hoboken: Wiley-Interscience; 2007.
31. Li BN, Chui CK, Chang S, Ong SH. A new unified level set method for semi-automatic liver tumor segmentation on contrast-enhanced CT images. *Expert Systems Appl*. 2012;39(10):9661-8. <https://doi.org/10.1016/j.eswa.2012.02.095>
32. Zidan A, Ghali NI, Hassanien AE, Hefny H, Hemanth J. Level set-based CT liver computer aided diagnosis system. *Int J Imaging Robotics*. 2012;9(1):26-36.
33. Cagnoni S, Dobrzeniecki AB, Poli R, Yanch JC. Genetic algorithm-based interactive segmentation of 3D medical images. *Image Vision Comput*. 1999;17(12):881-95. [https://doi.org/10.1016/S0262-8856\(98\)00166-8](https://doi.org/10.1016/S0262-8856(98)00166-8)
34. Ghosh P, Mitchell M. Segmentation of medical images using a genetic algorithm. In: *Proceedings of the 8th annual conference on Genetic and evolutionary computation GECCO*; 2006. p. 1171. <https://doi.org/10.1145/1143997.1144183>
35. Zhuo Z, Zhai W, Li X, Liu L, Tang J. Local adaptive segmentation algorithm for 3-D medical image based on robust feature statistics. *Sci China Inf Sci*. 2014;57(10):1-12. <https://doi.org/10.1007/s11432-014-5095-7>
36. Anastácio R, Thomaz RL, Macedo TAA, Patrocínio AC. Comparação entre técnicas para segmentação automática de fígado utilizando crescimento de região. *Rev Bras Inovação Tecnológica em Saúde*. 2015;5(4):1-12. <https://doi.org/10.18816/r-bits.v5i4.7061>
37. Kumar SS, Moni RS, Rajeev J. Automatic Segmentation of Liver and Tumor for CAD of Liver. *J Adv Inform Technol*. 2011;2(1):63-70. <https://doi.org/10.4304/jait.2.1.63-70>
38. Oliveira DA, Feitosa RQ, Correia MM. Segmentation of liver, its vessels and lesions from CT images for surgical planning. *BioMed Eng OnLine*. 2011;10(1):30. <https://doi.org/10.1186/1475-925X-10-30>
39. Lim SJ, Jeong YY, Ho YS. Automatic liver segmentation for volume measurement in CT Images. *J Vis Commun Image Rep*. 2006;17(4):860-75. <http://dx.doi.org/10.1016/j.jvcir.2005.07.001>
40. Heimann T, Meinzer HP. Statistical shape models for 3D medical image segmentation: a review. *Med Image Anal*. 2009;13(4):543-63. <https://doi.org/10.1016/j.media.2009.05.004>
41. Rueda L, Mery D, Kittler J. *Progress in Pattern Recognition Image Analysis and Applications*. Berlin: Springer; 2007.
42. Roerdink JBTM, Meijster A. The Watershed Transform: Definitions, algorithms and Parallelization Strategies. *Fundamenta Informaticae*. 2001;41(1-2):187-228.
43. Haralick RM, Shanmugam K, Dinstein IH. Textural features for image classification. *Systems, Man and Cybernetics*. 1973;6(6):610-21. <https://doi.org/10.1109/TSMC.1973.4309314>
44. Haralick RM. Statistical and structural approaches to texture. *Proceedings of the IEEE*. 1979;67(5):786-804. <https://doi.org/10.1109/PROC.1979.11328>
45. Zong X. *Sub-octave Wavelet Representation and Applications for Medical Image Processing [tese]*. Gainesville: University of Florida; 1997. 139 p.
46. Rubin RH. The effect of density variations on elemental abundance ratios in gaseous nebulae. *Astrophys J Suppl Series*. 1989;69:897-910.
47. Kononenko I. Machine learning for medical diagnosis: history, state of the art and perspective. *Artif Intell Med*. 2001;23(1):89-109.
48. Seeram E, Seeram D. Image postprocessing in digital radiology — a primer for technologists. *J Med Imaging Radiat Sci*. 2008;39(1):23-41. <https://doi.org/10.1016/j.jmir.2008.01.004>
49. Giger ML, Chan H-P, Boone J. History and status of CAD and quantitative image analysis: the role of Medical Physics and AAPM. *Med Phys*. 2008;35(12):5799-820. <https://doi.org/10.1118/1.3013555>
50. *Hologic Image Checker Analog CAD [Internet]*. Hologic Inc.; 2012 [acessado em 10 ago. 2019]. Disponível em: <http://www.alpha-imaging.com/products/computer aided diagnosis/hologic.prod/>
51. Nishikawa RM. Computer-aided Detection and Diagnosis. In: Brick U, Diekmann F. *Digital Mammography. Medical Radiology: Diagnostic Imaging and Radiation Oncology*. Alemanha: Springer; 2010. p. 85-106.

52. Sohns C, Angic BC, Sossalla S, Konietzschke F, Obenauer S. CAD in full-field digital mammography-influence of reader experience and application of CAD on interpretation of time. *Clin Imaging*. 2010;34(6):418-24. <https://doi.org/10.1016/j.clinimag.2009.10.039>
53. Fenton JJ, Taplin SH, Carney PA, Abraham L, Sickles EA, D'Orsi C, et al. Influence of computer-aided detection on performance of screening mammography. *New Eng J Med*. 2007;356(14):1399-409. <https://doi.org/10.1056/NEJMoa066099>
54. Malich AA, Fischer DR, Böttcher J. CAD for mammography: the technique, results, current role and further developments. *Eur Radiol*. 2006;16(7):1449-60. <https://doi.org/10.1007/s00330-005-0089-x>
55. Karssemeijer N. Computer aided detection in breast imaging: more than a perception aid. In: 2010 IEEE International Symposium on Biomedical Imaging: From Nano to Macro; 2010. Rotterdam; 2010. <https://doi.org/10.1109/ISBI.2010.5490360>.
56. Chen Y, Gale GA, Evanoff M. Does routine breast screening practice override display quality in reporting enriched test sets? In: Proceedings of SPIE Medical Imaging; 2013; Orlando. Orlando; 2013;8673:86730V-1-9.
57. Nishikawa RM. Mammographic databases. *Breast Dis*. 1998;10(3-4):137-50.
58. Ganesan K, Acharya UR, Chua CK, Min LC, Abraham KT, Ng KH. Computer-aided breast cancer detection using mammograms: a review. *IEEE Rev Biomed Eng*. 2013;6:77-98. <https://doi.org/10.1109/RBME.2012.2232289>
59. Schiabel H, Martinez AC, Vieira MAC, Escarpinati MC. Evaluating the influence of image acquisition system quality on a mammographic images processing scheme. In: Proceedings of SCAR Annual Meeting; 2005; Orlando. Orlando; 2005. p. 90-1.
60. Nishikawa RM, Yarusso LM. Variations in measured performance of CAD schemes due to database composition and scoring protocol. In: SPIE Medical Imaging. Proceedings. 1998;3338:840-4.
61. Schiabel H, Nunes FL, Escarpinati MC, Benatti RH. Investigations on the effect of different characteristics of images sets on the performance of a processing scheme for microcalcifications detection in digital mammograms. *J Digital Imaging*. 2001;14(2 Supl. 1):224-5. <https://doi.org/10.1007/bf03190347>
62. Góes RF, Schiabel H, Sousa MAZ. Automatic scanning software based on the characteristic curve of mammograms digitizers. *J Electronic Imaging*. 2013;22(1):013024-1-9. <https://doi.org/10.1117/1.JEI.22.1.013024>
63. Angelo MF, Patrocínio AC, Schiabel H, Medeiros RB, Pires SR. Comparison of changes in intensity of digital and digitized mammograms using intensity features analysis. *IEEE Eng Med Biol*. 2008;27(3):74-81.
64. Romualdo LS, Vieira MA, Schiabel H, Mascarenhas ND, Borges LR. Mammographic image denoising and enhancement using the Anscombe transformation, adaptive Wiener filtering and the Modulation Transfer Function. *J Digital Imaging*. 2013;26(2):183-97. <https://doi.org/10.1007/s10278-012-9507-1>