

2 Trabalhos Relacionados

O desenvolvimento de técnicas de aquisição de imagens médicas, em particular a tomografia computadorizada (TC), que fornecem informações mais detalhadas do corpo humano, tem aumentado a capacidade e fidelidade no diagnóstico de diversas doenças. Por outro lado, a dimensão destas imagens tem se tornado cada vez maior, aumentando a necessidade de técnicas de visão computacional para facilitar a interpretação.

Este capítulo tem o objetivo de prover uma revisão geral da literatura em análise automática de imagens de tomografia computadorizada (TC) da região do pulmão. Chama-se aqui TC do pulmão, a TC do tórax, cuja imagem envolve, além do pulmão, outros elementos do corpo, como órgãos, ossos e músculos. Como a aplicação discutida neste trabalho limita-se à região do pulmão, optou-se por referenciar tais imagens como “TC do pulmão”.

As seções seguintes estão divididas basicamente em duas partes. A Seção 2.1 apresenta uma revisão bibliográfica de trabalhos relacionados à detecção de nódulos pulmonares e a Seção 2.2 apresenta alguns trabalhos relacionados ao diagnóstico dos nódulos.

2.1. Detecção de nódulos pulmonares

O trabalho de Beigelman-Aubry et al. (2007) apresentou uma avaliação da detecção de nódulos e do seu tempo de resposta feita por radiologistas com e sem a utilização de um sistema computacional. O trabalho mostrou que o sistema melhora a sensibilidade de detecção, o que aumentou o intervalo de confiança em 2%. Entre os experimentos com 109 pacientes, houve um nódulo não detectado por um dos radiologistas, mas que foi identificado pelo sistema. Além disso, a utilização do sistema diminuiu consideravelmente o tempo de análise dos exames pelos especialistas.

Desta forma, os sistemas de detecção de nódulos, apesar de não darem o diagnóstico definitivo, têm grande importância nesse processo como uma “segunda opinião”.

Geralmente, os sistemas de detecção de nódulos envolvem quatro passos: pré-processamento, extração de candidatos a nódulo, redução de falsos positivos e classificação. O pré-processamento consiste, normalmente, em restringir o espaço de busca, delimitando o pulmão, e reduzir ruídos na imagem. A região do pulmão é segmentada e objetos candidatos a nódulo são identificados. Entre estes objetos a maioria dos não-nódulos é eliminada na fase de redução de falsos positivos. Os objetos restantes são, então, classificados em nódulo ou não-nódulo. Em alguns métodos, a redução de falsos positivos é realizada após a classificação. Alguns trabalhos encontrados na literatura envolvendo estes passos são apresentados nas subseções seguintes.

2.1.1. Delimitação do pulmão

Armato & Sensakovic (2004) mostraram a importância da segmentação adequada dos pulmões em sistemas de detecção e/ou diagnóstico assistido por computador. Seus estudos indicaram que até 17% dos nódulos pulmonares podem ser perdidos durante a segmentação dos pulmões se o algoritmo não estiver ajustado à tarefa de detecção de nódulos.

Um grande desafio é a segmentação de pulmões afetados com patologias de altas densidades junto à borda do pulmão. Devido à falta de contraste entre tais patologias e os tecidos adjacentes ao pulmão, métodos baseados em densidade falham nessa região. Nesse caso, é necessária alguma edição, mas, ainda assim, parte do pulmão é normalmente perdida. (Sluimer et al., 2006)

Devido à grande quantidade de ar no pulmão, seu interior tem tonalidade escura em imagens de TCs, diferentemente da região ao seu redor. Desta forma, o contraste entre o pulmão e tecidos vizinhos é base para a maioria dos métodos de segmentação de pulmão. A maioria dos métodos é baseada em regras (Hu et al., 2001; Zheng et al., 2003; Leader et al., 2003). A região do pulmão pode ser encontrada de duas formas (Sluimer et al., 2006). A primeira é através de

crescimento de região iniciando da traquéia. A segunda, mais usual, utiliza limiarizações e restrições de tamanho e localização.

2.1.2. Segmentação de nódulos

A seção anterior mostrou que a segmentação é um passo necessário e importante para análise de imagens e o seu resultado influencia no restante do processo.

Para encontrar candidatos a nódulo, as principais técnicas utilizadas são: limiarização múltipla (Armato et al., 1999; Ko & Betke, 2001; Zhao et al., 2004), morfologia matemática (Ezoe et al., 2002; Fetita et al., 2003; Tanino et al., 2003; Awai et al., 2004), aglomeração (*clustering*) (Kanazawa et al., 1998; Gurcan et al., 2002; Kubo et al., 2002; Yamada et al., 2003), análise de elementos conectados em imagens limiarizadas (Oda et al., 2002; Saita et al., 2004), limiarização (Wei et al., 2002; Mekadaa et al., 2003; Enquobahrie et al., 2004), detecção de círculos em imagens limiarizadas (Wiemker et al., 2002) e utilização de filtro de realce com elementos estruturais esféricos (Chang et al., 2004; Li & Dói, 2004; Paik et al., 2004).

Souza (2007b) propôs uma metodologia totalmente automática fundamentada em refinamentos sucessivos da segmentação sobre imagens de tomografia computadorizada utilizando técnicas morfológicas para a obtenção de candidatos a nódulo. A classificação foi efetivada por máquina de suporte vetorial (SVM) com base em características geométricas e de textura. Testes realizados sobre 33 casos mostraram que a metodologia atingiu 95,21% de acerto com uma média de 0,42 falsos positivos e 0,15 falsos negativos por exame.

Em Osman et al. (2007), para cada fatia, foram encontradas regiões de interesse (*region of interest* – ROI) usando os valores de densidade dos pixels. A união de todas as fatias formou 3D ROIs que, comparadas com um nódulo modelo (*template*), permitem identificar os nódulos. A sensibilidade alcançou 100%, porém os dados de teste restringiam-se em seis casos.

Retico et al. (2008) propôs um sistema baseado em filtro de realce para objetos esféricos e uma classificação neural baseada em voxel de regiões

selecionadas para reduzir falsos positivos. O desempenho do sistema foi avaliado em um conjunto de dados de 39 TCs e alcançou 80-85% de sensibilidade e 10-13 falsos positivos por exame.

Tong et al. (2007) desenvolveu um sistema de Diagnóstico Auxiliado por Computador (CADx) para imagens de TC de alta resolução (HRCT - *High-resolution computed tomography*) utilizando algoritmos de análise bidimensional e tridimensional. Esta técnica foi testada em oito casos de câncer no pulmão e obteve 95% de sensibilidade e 0,91 falsos positivos por fatia.

Para melhorar a sensibilidade da detecção, Li et al. (2008) usou um filtro de realce na fase de identificação e, para reduzir os falsos positivos, utilizou um classificador baseado em regras.

2.1.3. Identificação de nódulos

Uma vez que os objetos candidatos a nódulo são delineados nas imagens, atributos característicos destes objetos são calculados. Então, são utilizados classificadores que, a partir dos atributos, identificam os objetos candidatos no grupo nódulos ou no grupo não-nódulos.

Diversas técnicas podem ser usadas como classificadores no estágio final de detecção de nódulos: baseadas em regra ou classificador linear (Lee et al., 2001; Mekadaa et al., 2003; Chang et al., 2004), análise linear discriminante (Armato et al., 1999; Gurcan et al., 2002), combinando modelos (*template matching*) (Brown et al., 2002; Özkes, 2007), análise de aglomerado mais próximo (*nearest cluster*) (Ezoe et al., 2002; Tanino et al., 2003), máquina de suporte vetorial (Lu et al., 2004; Mousa & Khan, 2002; Sousa et al., 2007a; Opfer & Wiemker, 2007), redes neurais (Lo et al., 2003; Zhang et al., 2004; Ozkes et al., 2008) e classificador bayesiano (Farag et al., 2004; McCulloch et al., 2004). Os atributos mais usados para classificação são atributos baseados na densidade dos voxels, descrição de formas, relação espacial e informação de tamanho.

Sousa (2007a) propôs um conjunto de três atributos morfológicos desenvolvidas especialmente para a caracterização de nódulos pulmonares com os quais foram obtidos índices de acerto de 100% utilizando máquina de suporte

vetorial em uma base de dados com 38 casos.

2.1.4.

Redução de falsos positivos

Em alguns trabalhos, o classificador apresenta boa sensibilidade, porém um número alto de falsos positivos. Desta forma, tem-se procurado técnicas para reduzir este número após a identificação que, em alguns casos, funcionam como filtros antes da classificação. A redução de falsos positivos é importante, pois, mesmo que a sensibilidade permaneça inalterada, reduz-se o trabalho final do radiologista.

Em 1999, Armato et al. apresentou um método de detecção de nódulos pulmonares apenas com as etapas de pré-processamento, detecção de candidatos e classificação. Candidatos a nódulo foram encontrados através de limiarização múltipla e, em seguida, utilizando atributos de forma e densidade e análise linear discriminante, a classificação detectou 70% dos nódulos indicados por especialistas e 3 falsos positivos por fatia em média (aproximadamente 80-90 falsos positivos por exame). Em artigos posteriores, Armato e coautores se concentraram em técnicas para reduzir o número de falsos positivos: baseadas em regras (Armato et al., 2001; Arimura et al., 2004), análise de discriminante (Arimura et al., 2004; Armato et al., 2002) e redes neurais (Arimura et al., 2004; Suzuki et al., 2003). O melhor resultado obtido dessas técnicas foi de 80,3% na taxa de detecção com 4,8 falsos positivos por exame contra 27,4 sem redução de falsos positivos (Suzuki et al., 2003).

Lee et al. (2004) adicionaram a fase de redução de falsos positivos ao método de detecção de nódulos inicialmente proposto por Lee et al. (2001). Para isto, eles adicionaram cinco atributos de densidade e ajustaram os parâmetros de limiarização do modelo original. A sensibilidade do modelo continuou a mesma em 72,4%, mas a taxa de falsos positivos diminuiu de 30,8 para 5,5 por exame.

2.2.

Diagnóstico de nódulos pulmonares

É importante conhecer a natureza de um nódulo após sua detecção. O

desenvolvimento de métodos automáticos para auxiliar no diagnóstico de câncer no pulmão vem crescendo nos últimos anos (Sluimer et al., 2006).

Atualmente, os procedimentos mais confiáveis para determinar se um nódulo é maligno ou não são, na maioria, invasivos e envolvem riscos ao paciente (Diederich et al., 2002). Portanto, tem-se procurado métodos automáticos que ajudem a estimar a probabilidade de um nódulo ser cancerígeno (Ost & Fein, 2000; Yankelevitz & Henschke, 2000, Ko & Naidich, 2003). Para isto, é importante determinar quais características indicam a natureza de um nódulo.

Informações clínicas do paciente tais como idade, sexo, se é fumante, histórico de câncer e exposição a determinados componentes químicos ajudam a determinar a probabilidade de câncer. Gurney (1993) e Gurney et al. (1993) incluíram essas informações no diagnóstico de nódulos em radiografias do tórax.

As características mais importantes são o tamanho do nódulo e a taxa de crescimento cujas estimativas dependem fortemente da segmentação.

Silva (2004) desenvolveu um método para auxiliar no diagnóstico de nódulos através da análise de medidas de textura e geometria em imagens de TC. Foram analisados quatro grupos de atributos utilizando análise discriminante linear de Fisher e rede neural *perceptron* de múltiplas camadas.

McNitt-Gray et al. (1999) investigaram os efeitos de variar os parâmetros da matriz de coocorrência em 2D (direção, distância e quantização) no diagnóstico de nódulos. Os resultados mostraram que medidas de textura calculadas a partir dessas matrizes melhoram a identificação da natureza do nódulo.

O objetivo final de todos os trabalhos apresentados neste capítulo é o de tornar mais rápido e eficiente o diagnóstico precoce de câncer pulmonar, mas, para isto, é necessário detectar os nódulos existentes no pulmão. Como a segmentação faz parte dos estágios prévios deste processo, é necessário um bom método de segmentação, pois seu resultado determina todo o procedimento subsequente.