

統計解剖学的モデルに基づく 胸部 X 線 CT 画像からの肺病巣陰影の検出

石井 茂如^{1,a)} 滝沢 穂高²

受付日 2011年4月24日, 採録日 2011年10月3日

概要: 本研究の目的は胸部 X 線 CT 画像から肺結節 (肺がんの候補) を検出するための計算機診断支援 (CAD) システムを開発することである。我々の CAD システムの最も重要な構成要素の1つとして、結節と血管の3次元物体モデルを用いた結節認識手法であるモデルマッチング法を提案している。この手法は高い精度で結節を認識可能だが、いまだ十分ではない。そこで、本論文ではモデルマッチング法に以下の3つの改良を加える。第1に、肺野内血管の位置とサイズとの関係を表す統計的な分布モデルを構築する。これを事前知識として利用することによって、より信頼性の高い血管モデルを生成し、認識率を向上させる。第2に、血管に隣接する結節を認識するために結節モデルと血管モデルを組み合わせた新たなモデルを導入する。第3に、単円筒モデルを用いた新たなアルゴリズムを用いることで最適モデルの探索を高速化する。これらの改良を8mmスライス間隔のCT画像98例に適用したところ、TP率90%でのFP数を従来法の15.5[個/症例]から9.2[個/症例]に削減することができ、本手法の有効性が確認された。

キーワード: 肺結節検出, 胸部 X 線 CT, 偽陽性陰影削減, モデルマッチング, 肺血管分布モデル

Lung Lesion Detection from Chest X-ray CT Based on Statistical-anatomical Models

SHIGEYUKI ISHII^{1,a)} HOTAKA TAKIZAWA²

Received: April 24, 2011, Accepted: October 3, 2011

Abstract: The purpose of this work is to build a computer-aided diagnosis (CAD) system for detection of pulmonary nodules on thoracic X-ray computed tomography (CT) scans. As a core component of our CAD system, nodule recognition method based on three-dimensional nodule and blood vessel models was proposed. The method achieved high accuracy in recognition, but is not sufficient yet. Therefore, in this paper, we improve the model-based method as follows. First, the distribution of blood vessel sizes in lungs is modeled to represent the relationship between their sizes and positions in lungs. The distribution model is used as a priori knowledge for generating more reliable blood vessel models. Second, the nodule models are combined with the blood vessel models for recognizing nodules adjacent to blood vessels. Third, the model optimization is made faster by use of the improved algorithm based on simplified blood vessel models. The improved model-based recognition method is applied to actual 98 CT scans that include total 98 nodules. The number of false positives is successfully reduced from 15.5 per case by our previous method to 9.2 per case by the improved method at the 90% sensitivity.

Keywords: lung nodule detection, chest X-ray CT, false positive reduction, model-matching, the distribution models of lung blood vessels

¹ 東芝メディカルシステムズ株式会社
Toshiba Medical Systems Corporation, Ootawara, Tochigi
324-0036, Japan

² 筑波大学大学院システム情報工学研究科
Graduate School of Systems and Information Engineering,
University of Tsukuba, Tsukuba, Ibaraki 305-8573, Japan

a) shige0298@gmail.com

1. はじめに

死亡率が急増している肺がんの早期発見とそれともなう早期治療には X 線 CT を用いた集団検診が有効だといわれている [1]。近年はマルチスライス CT などの出現によ

り、高精度に肺がんを検出できるようになっているが、1被検者あたり数百枚にも及ぶ膨大な画像枚数を読影する必要があるため、放射線科医の負担が増大し、疲労によるがん陰影の見落としが懸念されている。そこで、画像を解析し放射線科医に第2の意見として情報提示する計算機診断支援 (CAD: Computer-Aided Diagnosis) システムの開発が急務となっている [2]。

肺がんの候補となる結節陰影を CT 画像から検出する手法として、Mathematical Morphology [3] フィルタの一種である Quoit フィルタを用いる方法 [4]、粒状と尾根状の陰影を強調するフィルタを用いる方法 [5], [6]、ベクトル集中度フィルタを応用した方法 [7] などがある。これらの手法は1次検出として用いられ、真の結節を逃さず検出することが求められるために大量の偽陽性陰影 (FP: False Positive) が過剰に検出される。この FP を削減する手法として、結節陰影と FP の濃淡特徴に識別関数を適用する手法 [8], [9], [10] や、結節や血管のモデルを用いた手法 [11], [12] が提案されている。モデルベースの認識手法は画像の幾何学的特徴も利用できるため、画像の濃淡特徴のみを用いる手法よりも高い精度が期待される。しかし、これらの手法ではモデルの形状や大きさについての解剖学的妥当性が検証されていない。この問題を解決した手法として、結節と血管の3次元モデルを用いたモデルマッチング法 [13] が提案されている。この手法は候補陰影の3次元的な幾何学特徴と解剖学的知識との関係を最大事後確率 (MAP: Maximum a Posteriori) 推定の枠組みで定式化することでより高精度に結節を認識することが可能だが、以下の3点について改良が必要であることが分かった。本論文ではこれらの改良をモデルマッチング法 [13] に加えることによって精度向上を図る。

(1) 統計データに基づく肺血管構造のモデル化と認識への適用

肺血管は心臓から肺野周辺部に向けて走行し、分岐を繰り返すことで徐々に細くなる。手法 [13] ではこの解剖学的特徴を単純な単調減少関数としてモデル化していたが、肺血管の構造は複雑であり、このモデルでは不十分であった。そこで、本論文では複数の CT 画像から肺の各所における血管の構造特徴を統計的に求め、認識に適用する手法を提案する。肺の3次元構造モデルを構築する方法として、肺の形態計測データの統計的な解析をもとにした数理モデル [14] が提案されている。しかし、肺内部の気管や血管は場所によって異なる特徴を持つため、一律な統計値から構築されたモデルでは、肺内部の構造を十分に表現しきれない。また、人体断面画像から半自動的に肺血管モデルを構築する方法 [15] も提案されている。しかし、処理の初期段階は人手で行う必要があり、人体断面画像の数も限られているため、統計的に信頼性の高いモデルを構築することは難しい。Mathematical Morphology フィルタによる肺血

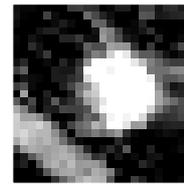


図 1 血管に隣接する結節

Fig. 1 A nodule adjacent to a blood vessel.

管径の解析 [16] も行われているが、肺血管の位置と構造との統計的な解析はなされていない。これに対して提案手法は、肺各所の統計値を算出することで複雑な血管構造を再現でき、完全に自動化された手法であるため大量のサンプルを処理可能となり、信頼性の高いモデルを構築することができる。

(2) 結節と血管の組合せモデルの導入

手法 [13] では候補陰影を含む関心領域 (VOI: Volume Of Interest) 内に結節か血管のどちらか一方のみが現れると仮定していたため、図 1 のように VOI 内に結節と血管が同時に発生した場合、モデルを正しくあてはめることができなかった。このような状態に対応するために、複数の物体モデルを組み合わせることでより複雑な組織構造を認識する手法 [17] が提案されているが、組合せの数は膨大であり、計算時間が大幅に増加した。そこで、組合せのパターンを限定した新たな組合せモデルを導入することで効率的な認識を試みた。

(3) 最適モデル探索法の改良

手法 [13] では2つもしくは3つの円筒モデルを組み合わせるによって血管樹状構造の部分構造を表現し、モデルの構造パラメータを同時に変化させることで候補陰影に対する最適モデルの探索を行っていた。そのため、各円筒モデルの数を n としたときに、最適モデルの探索に要する計算量はそれぞれ $O(n^2)$, $O(n^3)$ となり、探索が十分に行えずに候補陰影の組織構造を正しく再現できない場合があった。そこで、本論文では円筒モデルを1つだけ用意し、それを VOI にあてはめ、一致度の高い2つもしくは3つの円筒モデルを組み合わせることで樹状構造を持つ血管モデルを発生させる。最適モデルの探索は単一の円筒のみで行われるため、計算量は $O(n)$ となり、より高速で詳細な探索が可能となる。

以下、2章で従来手法のモデルマッチング法の概説を、3章で統計データに基づいた肺血管構造のモデル化について述べる。さらに、4章で新たな組合せモデルについて、5章で血管モデルの最適モデル探索法の改良について述べる。3~5章が本論文における新規提案であり、それらの有効性を6章の実験で検証する。最後に7章で結論を述べる。

2. MAP 推定に基づくモデルマッチング法

2.1 物体モデル

モデルマッチング法 [13] では、結節を図 2(a) に示す球形モデルで表す。球の半径を r^N とし、結節モデル o^N の生起確率を次式で定義する。

$$p(o^N) = P^N \cdot g(r^N) \quad (1)$$

ただし、 P^N はすべてのパターンの結節が発生する確率で、 $g(x)$ は正規分布を表す。

血管の湾曲部分は図 2(b) に示す 2 本の接続円筒で表す。湾曲血管モデル o^{B_c} の i 番目の円筒の半径を r_i 、各円筒どうしの接続面積の差を δ 、円筒どうしの角度を ψ とし、湾曲血管モデルの生起確率を次式で定義する。

$$p(o^{B_c}) = P^{B_c} \cdot \{g(r_1^{B_c}) \cdot g(\delta^{B_c}) \cdot g(\psi^{B_c})\}^{1/3} \quad (2)$$

指数 (式 (2) では $\frac{1}{3}$) は、正規分布の項数を正規化する補正係数で、この係数を導入した場合の方が導入しなかった場合に比べ認識精度が良いことが確認されている [13]。

式 (2) の半径 $r_1^{B_c}$ の正規分布の項はパラメータとして平均 $\mu_{r_1}^{B_c}$ と標準偏差 $\sigma_{r_1}^{B_c}$ を持つ。平均 $\mu_{r_1}^{B_c}$ は、血管の半径は肺野中心に近いほど太く、離れるほど細くなるという肺血管の解剖学的特徴を表現するために、手法 [13] では次式に示す関数として定義している。

$$\mu_{r_1}^{B_c}(x) = k_1 \exp(-k_2 \cdot |x - c^L|) \quad (3)$$

ただし、 x はモデルの肺野内での 3 次元位置、 c^L は肺野の中心座標、 $|x - c^L|$ は距離を表す。また k_1 、 k_2 は定数である。標準偏差 $\sigma_{r_1}^{B_c}$ は

$$\sigma_{r_1}^{B_c} = 5 \quad (4)$$

と固定していた。

血管の分岐部分は図 2(c) に示す 3 本の接続円筒で表す。分岐血管モデル o^{B_b} の生起確率を次式で定義する。

$$p(o^{B_b}) = P^{B_b} \cdot \{g(r_1^{B_b}) \cdot g(\delta_{23}^{B_b}) \cdot g(\delta_{123}^{B_b}) \cdot g(\psi_{12}^{B_b}) \cdot g(\psi_{13}^{B_b}) \cdot g(\psi_{23}^{B_b})\}^{1/6} \quad (5)$$

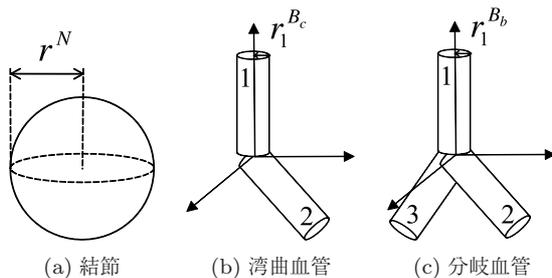


図 2 3次元物体モデル

Fig. 2 3-D deformable object models.

ただし、 $\delta_{23}^{B_b}$ は第 2, 第 3 円筒の接続面積の差を、 $\delta_{123}^{B_b}$ は第 1 円筒と第 2, 第 3 円筒との接続面積の差を表し、 $\delta_{123}^{B_b} = \pi((r_1^{B_b})^2 - (r_2^{B_b})^2 - (r_3^{B_b})^2)$ と計算する。 $\psi_{ij}^{B_b}$ は第 i 円筒と第 j 円筒との角度を表す ($i, j = \{1, 2, 3\}, i \neq j$)。

2.2 観測モデル

CT 画像再構成の手法を模した手法をモデルに適用することで疑似的な CT 画像を求め、実際の観測 CT 画像の VOI と比較することでモデルの生じた下での観測画像の生起する尤度を求める。

モデル o^τ の疑似 CT 画像の座標 x, y, z における画素値 $v^T(x, y, z; o^\tau)$ を次式により計算する。

$$v^T(x, y, z; o^\tau) = \alpha_m^\tau \cdot \zeta_m^\tau + \alpha_a^\tau \cdot (\zeta_v - \zeta_m^\tau) \quad (6)$$

ただし、 α_m と α_a はそれぞれモデルと周辺領域の X 線減衰率を表し、 $\tau \in \{N, B_c, B_b\}$ である。 ζ_v は VOI 全体の体積、 ζ_m はモデルと VOI が重なる領域の体積を表す。

結節候補陰影の観測画像と物体モデルとの一致度を

$$\gamma(v^c, v^T) = \frac{\sum_{x,y,z} (v^c(x, y, z) - \bar{v}^c)(v^T(x, y, z) - \bar{v}^T)}{\sqrt{\sum_{x,y,z} (v^c(x, y, z) - \bar{v}^c)^2} \sqrt{\sum_{x,y,z} (v^T(x, y, z) - \bar{v}^T)^2}} \quad (7)$$

とし、この一致度を用いて、尤度を

$$p(v^c | o^\tau) = \frac{\gamma(v^c, v^T) + 1}{2} \quad (8)$$

と定義する。ただし、 $v^c(x, y, z)$ は候補陰影の観測画像の座標 x, y, z における画素値を表す。 \bar{v}^c と \bar{v}^T はそれぞれ候補点の観測画像の平均値と疑似 CT 画像の平均値を表す。

2.3 MAP 推定に基づく結節と血管の識別

モデルの生起確率と尤度を用いて次式により各モデルの事後確率を計算する。

$$p(o^\tau | v^c) = \frac{p(v^c | o^\tau) \cdot p(o^\tau)}{p(v^c)} \quad (9)$$

ただし、 $\tau \in \{N, B_c, B_b\}$ であり、 v^c は候補陰影の観測画像を表す。式 (9) を最大化させるそれぞれの最適モデル $o^{*\tau}$ を求める。

結節と血管の識別には、次式の後確率比を用いる。

$$\rho(v^c) = \frac{p(o^{*N} | v^c)}{\max_{\tau \in \{B_c, B_b\}} p(o^{*\tau} | v^c)} \quad (10)$$

ρ が閾値 T_ρ 以上であれば結節 (異常)、 T_ρ 未満であれば血管 (正常) と判断する。

3. 統計データに基づく肺血管構造のモデル化とモデルマッチング法への適用

前述したように式 (3) と式 (4) による肺血管径のモデル化は不十分であった. そこで, 肺臓器各所における血管構造の特徴の統計値を要素値とする 3次元配列を生成し, 認識に利用する. 本論文ではこれを肺血管分布モデルと呼ぶ. ここでは血管構造の特徴のうち, 最も重要と考えられる血管径の平均と標準偏差の分布モデルを構築する.

3.1 肺血管平均径分布モデルの構築手順

構築の流れを図 3 に示す. まず, i 番目の CT 画像 V^i に rolling-ball アルゴリズム [18] を適用して肺野領域を抽出し, 続いて 2 値化ベースの肺血管領域抽出, 距離変換, Hilditch の細線化を適用することで, 肺血管領域の中心線上の画素がその位置での血管半径を表す肺血管径画像 R^i を生成する. 次に肺野領域に外接する直方体を肺血管径画像 R^i に設置し, 外接直方体を基準に CT 画像間の位置合わせを行う. さらに, 外接直方体を $L \times M \times N$ 個の小さな直方体領域 (セル, Cell と呼ぶ) に分割する. x, y, z 軸方向についてそれぞれ l, m, n 番目のセルが中心線画素を含む場合, その血管半径値の平均を求め $u_{l,m,n}^i$ と表す. 平均半径値の集合を $U_{l,m,n} = \{u_{l,m,n}^{i_1}, u_{l,m,n}^{i_2}, \dots\}$ と表す.

CT 画像における各スライス画像には, スライスに相当する断面の近傍領域 (今回の画像は 8mm スライス間隔なので, -4mm から $+4\text{mm}$ の間の空間) に存在する臓器構造が射影されて写り込む. したがって, その近傍領域内で円筒状の血管が直線もしくはそれに近い状態で存在する場合, 血管は円状もしくは楕円状の領域となって観測され, さらにその領域の短軸方向の直径 (いわゆる領域の幅) はその血管の直径に近い値になる. 本節の肺血管領域抽出では, 幅約 2.5mm 以上の領域が抽出可能なので, 直径約 2.5mm 以上の血管が抽出可能であると考えら

れる. また血管半径の測定精度はスライス画像の解像度が 0.625 [mm/pixel] の CT 画像上で測定を行うため, 短軸方向に関しては 0.625 [mm] であると考えられる.

肺血管領域抽出の際に横隔膜などの血管以外の組織が誤抽出される場合がある. これらは非常に太い, または細かい血管として誤認識され, 正確なモデル構築の妨げとなる. そこで, この影響を軽減させるために, $U_{l,m,n}$ をソートし, 上位 N_c 個と下位 N_c 個を削除する.

肺血管平均径分布モデルの座標 l, m, n における要素値 $D_r(l, m, n)$ は次式で計算される.

$$D_r(l, m, n) = \begin{cases} \frac{\sum_{u \in U_{l,m,n}} u}{\# \{U_{l,m,n}\}} & \frac{\# \{U_{l,m,n}\}}{I} \geq T_p \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

ただし, $\# \{U_{l,m,n}\}$ は集合 $U_{l,m,n}$ の要素数を表し, I は症例数を表す. $\frac{\# \{U_{l,m,n}\}}{I}$ は l, m, n 番目のセルに中心線画素の含まれる割合を表している. この割合が T_p より低い場合, 統計値に信頼性がないと判断し, $D_r(l, m, n)$ に 0 を設定する.

3.2 肺血管径標準偏差分布モデルの構築手順

肺血管平均径分布モデルと同様に, l, m, n 番目のセルが中心線画素を含む場合にその血管半径値の標準偏差を求め $s_{l,m,n}^i$ と表す. 標準偏差の集合を $S_{l,m,n} = \{s_{l,m,n}^{i_1}, s_{l,m,n}^{i_2}, \dots\}$ と表し, 上位 N_c 個と下位 N_c 個を削除する. 肺血管径標準偏差分布モデルの座標 l, m, n における画素値 $D_{sd}(l, m, n)$ を次式により計算する.

$$D_{sd}(l, m, n) = \begin{cases} \frac{\sum_{s \in S_{l,m,n}} s}{\# \{S_{l,m,n}\}} & \frac{\# \{S_{l,m,n}\}}{I} \geq T_p \\ 0 & \text{otherwise} \end{cases} \quad (12)$$

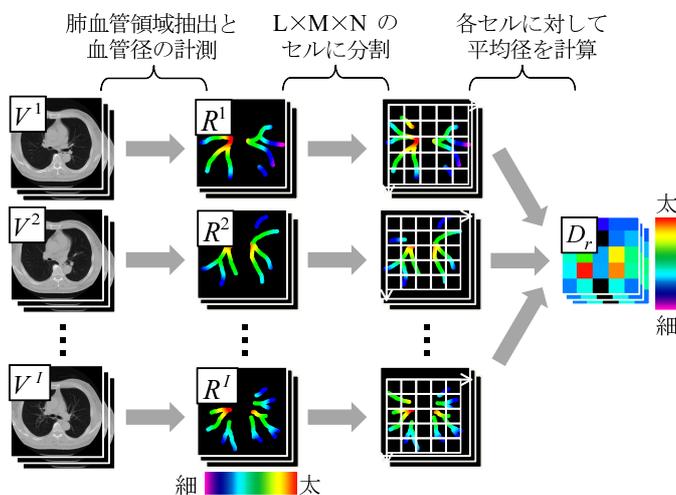


図 3 肺血管平均径分布モデルの構築手順

Fig. 3 Construction procedure of the distribution model of means of blood vessel radii.

3.3 モデルマッチング法への適用

候補陰影の肺野内での位置から、候補陰影を含むセルを求め、そのセルの平均と標準偏差を式 (3) と式 (4) の代わりに用いることによって、式 (2) と式 (5) の血管径の確率 $g(r_1^{Bc})$ と $g(r_1^{Bb})$ を計算し、湾曲と分岐血管モデルの事前確率を求める。

4. 結節・血管組合せモデル

血管に隣接する結節を認識するための新たなモデルとして、結節モデルと湾曲血管モデルを組み合わせた結節湾曲血管組合せモデル o^{NBc} 、結節モデルと分岐血管モデルを組み合わせた結節分岐血管組合せモデル o^{NBb} を導入する。

図 4 に生成手順を示す。まず手法 [13] と同様に式 (9) の事後確率を最大化する最適モデルを探索する。組合せモデルはそれらの最適モデルを組み合わせて生成する。各組合せモデルの事前確率を次式で定義する。

$$p(o^{NBc}) = P^{NBc} \cdot \{g(r^N) \cdot g(r_{r1}^{Bc}) \cdot g(\delta^{Bc}) \cdot g(\psi^{Bc})\}^{1/4}, \quad (13)$$

$$p(o^{NBb}) = P^{NBb} \cdot \{g(r^N) \cdot g(r_{r1}^{Bb}) \cdot g(\delta_{23}^{Bb}) \cdot g(\delta_{123}^{Bb}) \cdot g(\psi_{12}^{Bb}) \cdot g(\psi_{13}^{Bb}) \cdot g(\psi_{23}^{Bb})\}^{1/7} \quad (14)$$

ただし、 P^{NBc} はすべてのパターンの結節湾曲血管組合せモデルが発生する確率、 P^{NBb} はすべてのパターンの結節分岐血管組合せモデルが発生する確率を表す。

組合せモデルを生成する際に、図 4 右下 (*で示した) のように、結節モデルの大部分が血管モデルに包含される場合がある。このとき、血管モデルと組合せモデルの疑似 CT 画像が酷似するため、血管陰影にも組合せモデルがあてはまり、偽陽性となってしまふ。このような事態を避けるため、血管モデルの疑似 CT 画像と組合せモデルの疑似

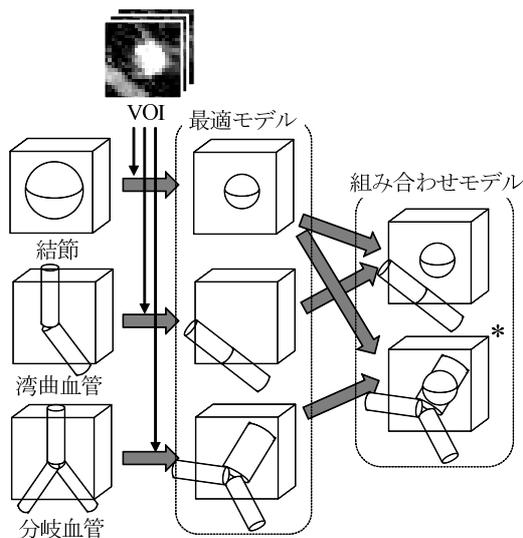


図 4 結節・血管組合せモデルの生成手順

Fig. 4 Generating procedure of the combination models of nodules and blood vessels.

CT 画像の一致度を式 (7) により計算し、閾値 T_γ 以下ならばその組合せモデルを削除する。

組合せモデルを用いた場合の候補点の正・異常の判別には、式 (10) の代わりとして次式を用いる。

$$\rho'(v^c) = \frac{\max_{v \in \{N, NBc, NBb\}} p(o^v | v^c)}{\max_{\tau \in \{Bc, Bb\}} p(o^\tau | v^c)} \quad (15)$$

5. 最適モデル探索法の改良

方位角と天頂角がそれぞれ θ と φ の単円筒モデル (図 5 (a) 参照) を $o^{Bs}(\theta, \varphi)$ と表す。湾曲血管モデルの最適モデルを以下の手順により求める。

θ と φ を $\Delta\theta$ と $\Delta\varphi$ ごとに変化させながら式 (8) により尤度 $p(v^c | o^{Bs}(\theta, \varphi))$ を計算する。尤度の最も大きい単円筒モデルから順に単円筒モデルの集合 C に追加する。ただし、すでに C に含まれる単円筒モデルとのなす角度が T_θ 以下になる場合は追加しない。この追加処理を C の要素数が N_{Bs} となるまで続ける。 C から 2 つのモデルを選択して湾曲血管モデルを構成し、式 (9) により事後確率を計算する。 C から選択される全通りの単円筒モデルの組合せで湾曲血管モデルを構成し、最も事後確率の高いモデルを最適湾曲血管モデルとする。

分岐血管モデルについても同様の手順で最適モデルの探索を行う。 C に追加する単円筒モデルに角度の制限を加えた理由は、図 5 (b) のような極端な鋭角度で接続する湾曲血管モデルは解剖学的に存在しないと考え、これを排除するためである。

6. 実験

6.1 肺血管分布モデルの構築

健常者の胸部 X 線 CT 画像 48 症例から肺血管分布モデルを構築した。これらの撮影条件を表 1 に示す。スライス数は 31~44 である。また、実験に必要なパラメータを表 2 (a) のように設定した。これらの値は実験的に決定した。

構築された肺血管平均径分布モデルと肺血管径標準偏差分布モデルを図 6 (a), 図 6 (b) に示す。肺中部の分布を示す図 6 (a-2), (a-3), (a-4) を見ると、右肺の中心部と左肺

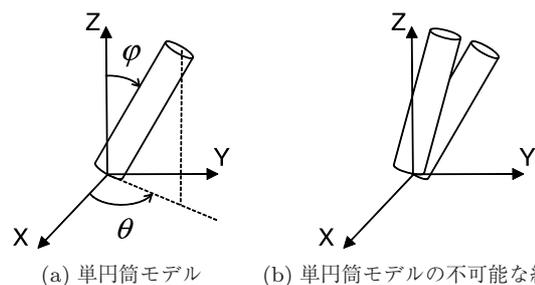


図 5 単円筒モデル

Fig. 5 Single cylinder model.

表 1 CT 画像の撮影条件

Table 1 Acquisition parameters of CT scans.

Image size	512 × 512 pixel
Pixel size	0.625 × 0.625 mm
Slice thickness	8 mm

表 2 実施パラメータ

Table 2 Parameters for experiments.

(a) 肺血管分布モデル構築実験のパラメータ

パラメータ	設定値
CT 画像をセルに分割する際の分割数 $L \times M \times N$	30 × 20 × 31
症例の除去数 N_c	2
肺血管存在確率の閾値 T_p	0.1

(b) 性能比較実験のパラメータ

パラメータ	設定値
一致度の閾値 T_γ	0.92
単円筒モデルの方位角の探索角度 $\Delta\theta$	$\pi/36$
単円筒モデルの天頂角の探索角度 $\Delta\psi$	$\pi/20$
単円筒モデルどうしのなす角度の閾値 T_θ	$\pi/4$
単円筒モデルの集合サイズ N_{B_s}	25

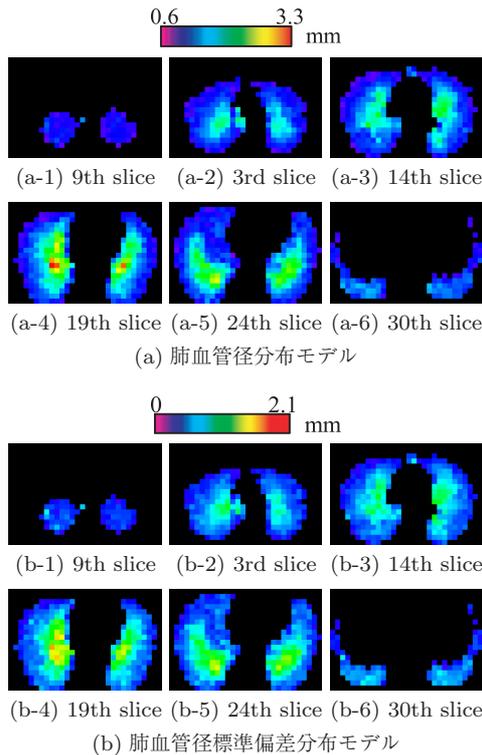


図 6 肺血管分布モデル

Fig. 6 The distribution models of blood vessels.

の中心部に太い血管が分布している。これに対して、肺下部では図 6 (a-5) のように背側に太い血管が分布している。式 (3) では、肺野中心が最も太くなるため、図 6 (a-5) とは異なる分布となる。また、図 6 (b) に示す標準偏差も平均径と似た分布を示している。手法 [13] では標準偏差を位置にかかわらず定数 5 で固定していたため、図 6 (b) と大

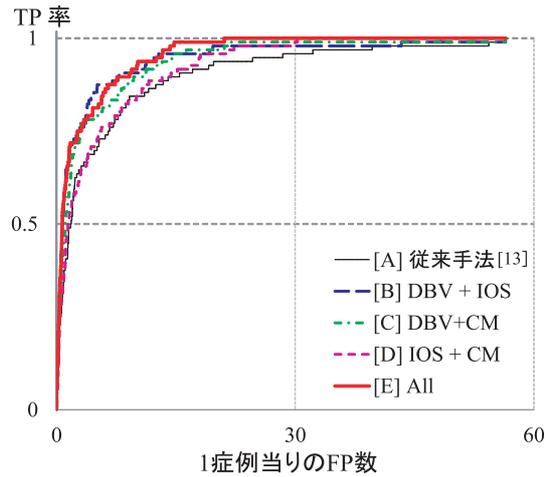


図 7 従来手法と提案手法の性能曲線

Fig. 7 The performance curves of the previous method and the proposed method.

きく異なる。このように、統計モデルと手法 [13] のモデルでは差異が見られるため、認識に利用した場合の精度も異なると考えられる。次節以降ではこの分布モデルをモデルマッチング法に適用し、その有効性を検証する。

6.2 性能比較実験

6.2.1 実験条件

実験には放射線科医によって異常と診断された実症例 98 例を用いる。これらの撮影条件は表 1 と同様で、スライス数は 30~42 である。また、 $\phi 3\text{ mm}$ 以上 $\phi 10\text{ mm}$ 以下の異常陰影を 98 個含む。これらの症例に対して、判別フィルタと SVM による結節検出手法 [19] を適用した結果、FP が 1 症例あたり 56.4 個、真の異常陰影 (TP: True positive) が 96 個検出され、見落としは 2 個だった。

モデルマッチング法のパラメータは文献 [13] と同様に設定し、提案手法のパラメータは表 2 (b) のように設定した。これらの値は実験的に決定した。計算機環境は、CPU: Intel Xeon X5355 2.66 GHz、メモリ: 12 GB である。

6.2.2 実験結果

前項の候補陰影群にモデルマッチング法 [13] と提案手法を適用し、性能を比較した。結果の FROC 曲線を図 7 に示す。FROC 曲線は異常陰影の検出率と 1 症例あたりの FP 数の関係を表す曲線で、CAD の性能評価に用いられる。図 7 は式 (10) に対する閾値 T_p を変化させながら描いた。DBV が肺血管分布モデル、CM が組合せモデル、IOS が改良最適モデル探索法を導入した結果を表す。All はこれらすべてを導入した結果を表す。表 3 には各 TP 率における具体的な FP 数を示している。従来手法と比べ、提案手法が FP 数を削減できていることが分かる。以下では実験結果のうちの 2 症例について詳細に検討する。

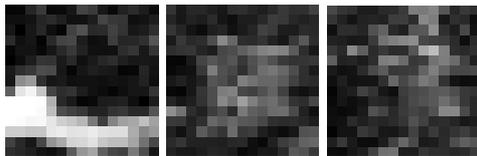
6.2.3 症例 1

図 8 (a) にモデルマッチング法 [13] で最も識別困難だっ

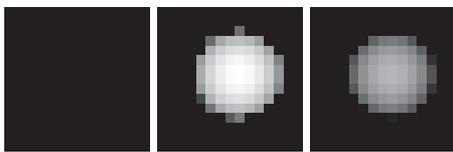
表 3 従来手法と提案手法の FP 数の比較

Table 3 Comparison of the numbers of FPs of the previous method and the proposed method.

TP 率 [%]	FP 数 [/症例]		
	[A] 従来手法 [13]	提案手法	
		[B] DBV+IOS	[E] All
100	56.4	56.4	22.3
95	28.4	19.2	14.8
90	15.5	9.7	9.2



(a) モデルマッチング法 [13] で最も識別困難だった結節陰影の VOI

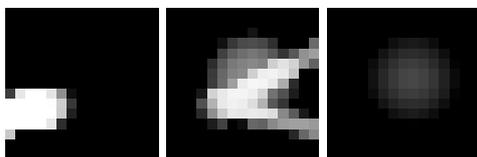


(b-1) 結節モデル



(b-2) 分岐血管モデル

(b) モデルマッチング法 [13] により生成された最適モデルの疑似 CT 画像

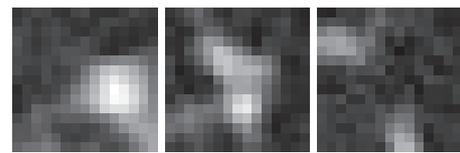


(c) 提案手法により生成された結節分岐血管組合せモデルの疑似 CT 画像

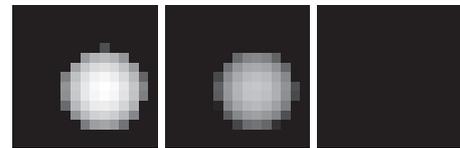
図 8 症例 1

Fig. 8 Case1.

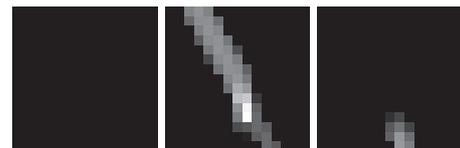
た結節陰影の VOI を示す。中央の画像が手法 [19] が検出した陰影で、左の画像が上スライスの同じ位置の画像で、右は下スライスの画像である。中、下スライスにすりガラス状の淡い結節陰影を確認でき、上スライスに血管陰影を確認できる。この候補にモデルマッチング法 [13] を適用して得られた最適モデルの疑似 CT 画像を図 8(b) に示す。結節モデルは結節陰影にあてはまり、分岐血管モデルも血管陰影にあてはまっているが、結節と血管の両方の陰影を同時にあてはめることができなかった。事後確率比は $\rho = 0.26$ となり、血管と誤認識された。これに対し、提案手法の結節分岐血管組合せモデル (図 8(c) 参照) では結節陰影と血管陰影の両方にあてはめることができている。事後確率比は $\rho' = 0.93$ まで上昇し、結節と正しく認識された。



(a) 血管陰影の VOI

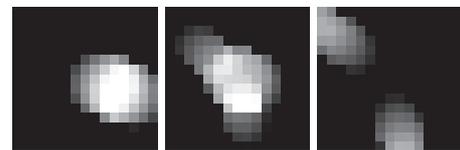


(b-1) 結節モデル



(b-2) 分岐血管モデル

(b) モデルマッチング法 [13] により生成された最適モデルの疑似 CT 画像



(c) 提案手法により生成された分岐血管モデルの疑似 CT 画像

図 9 症例 2

Fig. 9 Case2.

6.2.4 症例 2

図 9(a) に血管陰影の VOI を示す。図 9(a) では上スライスを貫く太い血管が中心スライスで 2 本の細い血管に分岐している。下スライスには分岐した血管が確認できる。モデルマッチング法 [13] により生成された最適モデルの疑似 CT 画像 (図 9(b) 参照) を見ると、分岐血管モデルの半径が図 9(a) の血管陰影よりも細く、上下スライスの陰影にも正しくあてはめられていない。これに対して、提案手法の分岐血管モデル (図 9(c) 参照) は血管構造を正確に再現できている。

この候補は肺下部に現れたため、モデルマッチング法 [13] における血管径決定式 (3) によって 0.85 mm と小さい半径が設定された。これに対して、肺血管平均径分布モデルでは統計的に太い血管が存在すると示されており、半径には 1.52 mm が設定された。実際にこの位置に発生した図 9(a) の血管陰影に対しては提案手法の方がより近い血管径を設定できている。また、図 9(b-2) では上下スライスのあてはめが不完全であるのに対して、提案手法では最適モデル探索法が改良されたことで図 9(c) のように適切にあてはめることができている。

事後確率比はモデルマッチング法 [13] の $\rho = 1.48$ から提案手法の $\rho' = 0.71$ となり、正常陰影であると正しく識別された。

6.2.5 考察

図7の手法[A], [B], [C], [D]を比較すると, 肺血管分布モデルを持つ手法[B], [C]の性能が肺血管分布モデルを持たない手法[A], [D]を上回っている. この結果から, 血管構造の統計的特徴を利用することで結節の識別性能が向上することが示され, さらに提案手法の性能向上に最も寄与しているのは肺血管分布モデルの導入であることも分かる. また, 表3のTP率100%における手法[B]と[E]のFP数を比較すると, 手法[E]がFP数を大幅に抑えられていることが分かる. 組合せモデルを持たない手法[B]は6.2.3項の症例1のような血管に隣接する結節の認識が困難であり, これがTP率100%におけるFP削減を妨げていた. 手法[E]ではこのような候補陰影の認識に特化した組合せモデルを導入することで, 精度が向上した. 一方, 図7のTP率85%付近においては手法[B]と[E]の性能が逆転している. これは, 組合せモデルの導入により異常だと判定される正常陰影が増加したことが原因だと考えられる. この副作用は一致度の閾値 T_g による組合せモデルの削除によってある程度抑えられているが, 完全に取り除くためにはさらなる改良を要する. また, 図8(c)では上スライスの血管陰影にのみ分岐血管モデルがあてはまるべきだが, 中心スライスにも現れている. これは, 処理時間削減のために物体モデルが中心スライス付近に必ず位置するように制限しているからであり, 図8(a)のような組織構造を完全に再現するためには新たな組合せ法の考案が必要となる.

本論文では比較的大きなスライス間隔を持つ8mmスライス間隔のCT画像を実験に用いたが, 本手法はスライス間隔の大小にかかわらず適用可能である. スライス間隔が大きいくほど画像枚数が少ないため認識が困難になると考えられるが, 本実験のように, より認識困難な8mmスライス間隔のCT画像に対して精度向上を達成したことから, 本手法はスライス間隔の大きいCT画像から小さいCT画像まで高精度に病巣候補を識別できると考えられる.

最後に, 計算コストについて述べておく. モデルマッチング法[13]では合計740,620個のモデルから最適モデルを探索する必要があり, この探索処理に1候補点あたり10.96秒要していたが, 提案手法では5章の最適モデル探索法の改良によって探索すべきモデル数が7,562個まで削減され, 探索時間は3.24秒に削減された. 全体の処理時間は, モデルマッチング法[13]が1候補点あたり14.3秒であり, 提案手法(改良をすべて導入した場合)が6.9秒であった. このように, 提案手法では計算コストを抑えつつ精度を向上させることができたといえる.

7. おわりに

本論文では, 結節検出手法であるモデルマッチング法[13]に3点の改良を加えた. まず, 肺血管のモデル化が不十分

であるという問題を解決するために, 統計データに基づいて肺血管構造をモデル化した. このモデルを解剖学的知識としてモデルマッチング法に適用することで, より信頼性の高い血管モデルが生成された. 次に, 血管に隣接した結節を認識するための結節・血管組合せモデルを提案した. 最後に, 単円筒モデルを用いた新たなアルゴリズムを用いることで最適モデルの探索法を高速化した. これらの改良を導入したモデルマッチング法を, 8mmスライス間隔の検診用CT画像から抽出された結節候補陰影に対して適用したところ, TP率100%におけるFP数が56.4[個/症例]から22.3[個/症例]に削減され, 本手法の有効性を確認した.

今後の課題としては3点あげられる. 第1に, Thin-slice(薄層スライス)CTに対する手法の適用である. スライス間隔が小さい場合, モデルがより詳細な陰影構造をとらえることで観測画像とモデルの一致度(式(7))が向上し, 結果的に認識精度も向上すると考えられる. 肺血管分布モデルにおいては利用できる画像枚数が増えることで分布モデルの統計的信頼性が向上し, さらに3次元的に肺血管を抽出することで肺各所における血管の3次元的方向もモデル化することができ, 認識精度向上に寄与すると考える. 第2に, さらなる精度改善策として結節モデルの改良があげられる. 初期段階の小さい結節は球形で発生することが知られているが, 末期になると結節が肥大化し, 形状が楕円形や一部が突出した球に変化していく. 提案手法では結節を完全な球としてモデル化していたため, 球形以外の結節に対応できない. そこで, 球以外の形状を再現可能な新たな結節モデルを考案することで様々な形状の結節を再現し, 識別精度の向上を図る. 第3に, 他の手法との性能比較である. 本論文ではモデルマッチング法[13]と提案手法の性能比較のみ行ったが, 他の手法との比較も重要だと考え, 今後実施していく.

参考文献

- [1] 館野之男, 飯沼 武, 松本 徹ほか: 肺癌検診のためのX線CTの開発, 新医療, Vol.17, No.10, pp.28-32 (1990).
- [2] 負門克典, 松迫正樹: 大容量CT時代の読影の問題点, *Medical Imaging Technology*, Vol.25, pp.84-88 (2007).
- [3] Haralick, R.M., Sternberg, S.R. and Zhuang, X.: Image analysis using mathematical morphology, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.9, No.1, pp.532-550 (1987).
- [4] Yamamoto, S., Matsumoto, M., Takano, Y., et al.: Quoit Filter - A New Filter Based on Mathematical Morphology to Extract the Isolated Shadow, and Its Application to Automatic Detection of Lung Cancer in X-ray CT, *Proc. 13th International Conference on Pattern Recognition*, pp.3-7 (1996).
- [5] Sato, Y., Nakajima, S., Shiraga, N., et al.: Three-dimensional multi-scale line filter for segmentation and visualization of curvilinear structures in medical images, *Medical Image Analysis*, Vol.2, No.2, pp.143-168 (1998).
- [6] Li, Q., Sone, S. and Doi, K.: Selective enhancement filters for nodules, vessels, and airway walls in two- and

- three-dimensional CT scans, *Medical Physics*, Vol.30, No.8, pp.2040-2051 (2003).
- [7] 澁谷倫子, 杉浦彰彦, 滝沢穂高ほか: 可変 N-Quoit とベクトル集中度の併用による肺結節陰影の検出, *信学論*, Vol.J93-D, No.8, pp.1491-1501 (2010).
- [8] Matsumoto, S., Kundel, H.L., Gee, J.C., et al.: Pulmonary nodule detection in CT images with quantized convergence index filter, *Medical Image Analysis*, Vol.10, pp.343-352 (2006).
- [9] 野村行弘, 根本充貴, 増谷佳孝ほか: 胸壁付着結節に対応した識別器の追加による肺結節自動検出法の改良, *Medical imaging technology*, Vol.27, No.2, pp.123-131 (2009).
- [10] Murphy, K., Ginneken, B.V., Schilham, A.M., et al.: A large-scale evaluation of automatic pulmonary nodule detection in chest CT using local image features and k-nearest-neighbour classification, *Medical Image Analysis*, Vol.13, pp.757-770 (2009).
- [11] Lee, Y., Hara, T., Fujita, H., et al.: Automated detection of pulmonary nodules in helical CT images based on an improved template-matching technique, *IEEE Trans. Medical Imaging*, Vol.20, No.7, pp.595-604 (2001).
- [12] Farag, A., El-Baz, A., Gimel'farb, G., et al.: Detection and recognition of lung abnormalities using deformable templates, *Proc. 17th International Conference on Pattern Recognition*, pp.738-741 (2004).
- [13] Takizawa, H., Yamamoto, S. and Shiina, T.: Recognition of Pulmonary Nodules in Thoracic CT Scans Using 3-D Deformable Object Models of Different Classes, *Algorithms*, Vol.3, No.2, pp.125-144 (2010).
- [14] Kitaoka, H., Takaki, R. and Suki, B.: A three-dimensional model of the human airway tree, *J. Appl. Physiol.*, Vol.87, pp.2207-2217 (1999).
- [15] 滝沢穂高, 深野元太郎, 山本眞司ほか: 人体断面画像からの3次元肺血管・気管モデルの構築, *コンピュータ支援画像診断学会論文誌 (on J-STAGE)*, Vol.5, No.9, pp.1-10 (2001).
- [16] Masutani, Y., MacMahon, H. and Doi, K.: Quantitative analysis on spatial distribution of vascular sizes in lung using three-dimensional greyscale morphology, *Proc. 22nd Annual EMBS International Conference*, p.2028 (2000).
- [17] 滝沢穂高, 山本眞司, 中川徹ほか: 3次元マルコフ確率場モデルを用いた胸部 X 線 CT 画像からの結節陰影の認識, *信学論*, Vol.J85-D-II, No.9, pp.1401-1412 (2002).
- [18] Sternberg, S.R.: *Biomedical Image Processing*, *IEEE Comput.*, Vol.16, No.1, pp.22-34 (1983).
- [19] Takizawa, H., Nishizako, H., Wada, S. and Matsumoto, T.: Lung Cancer Detection From XRay CT Images Using Pixel-based Support Vector Machine, *Proc. 12th IASTED International Conference, Signal and Image Processing*, pp.88-92 (2010).



石井 茂如 (正会員)

計算機診断支援の研究に従事。

2011年筑波大学大学院システム情報工学研究科コンピュータサイエンス専攻博士前期課程修了。同年東芝メディカルシステムズ株式会社入社。現在、研究開発センターに勤務。大学院在学中は、医用画像認識、特に肺がんの計



滝沢 穂高 (正会員)

コンピュータビジョンの研究に従事。電子情報通信学会、画像電子学会、日本医用画像工学会、日本生体医工学会、IEEE 各会員。

1998年大阪大学大学院工学研究科電子制御機械工学専攻博士後期課程修了。博士(工学)。同年豊橋技術科学大学助手、2005年筑波大学大学院システム情報工学研究科講師。2008年同准教授、現在に至る。医用画像認識、