

ガボールフィルタを用いた 肺結節陰影診断支援システム

Computer Aided Diagnosis System for Pulmonary Nodules Using Gabor Filter

○ 武井 一典*, 本間 経康*, 石橋 忠司*, 酒井 正夫*, 吉澤 誠*, 阿部 健一**

○ Kazunori Takei*, Noriyasu Homma*, Tadashi Ishibashi*, Masao Sakai*,
Makoto Yoshizawa*, and Kenichi Abe**

*東北大学, **日本大学

*Tohoku University, **Nihon University

キーワード: コンピュータ診断支援 (Computer aided diagnosis), 肺結節 (Pulmonary nodule), ガボールフィルタ (Gabor filter), フラクタル次元 (Fractal dimension), 2段階鑑別 (2 stages discrimination)

連絡先: 〒980-8579 仙台市青葉区荒巻字青葉6-6-05 東北大学大学院工学研究科 電気・通信工学専攻 吉澤研究室
武井 一典, Tel.: (022)795-7130, Fax.: (022)263-9163, E-mail: takei@yoshizawa.ecei.tohoku.ac.jp

1. はじめに

近年, 肺がんによる死亡者数の増加に伴い, その早期発見のためにX線CTが多く診断に用いられるようになった¹⁾²⁾³⁾. このCTによる診断方法は, 肺がんの検出率が高い反面, 患者1人当たり数十枚ものスライスが生成され, 集団検診の場でこの読影を全て医師に任せるには, 負担が大きすぎるという問題がある. このような問題に対してこれまでに, 肺結節陰影を自動で検出し, 医師へ提示することで, 医師の負担を軽減するためのコンピュータ診断支援 (computer-aided diagnosis: CAD) システムがいくつか提案されている. 三輪らは, 孤立性陰影を検出する可変N-Quoitフィルタを提案した⁵⁾. また, Leeらは遺伝的アルゴリズムを用いた肺結節自動検出を試みた⁶⁾. しかし, これらのCADシステムは高い真陽性 (true positive: TP) 率

で肺結節を検出することができるが, 同時に偽陽性 (false positive: FP) 率も高く, まだまだ臨床では使用しにくいという状況であった. これに対し, FPを減らすことを目的とした研究もなされている⁴⁾. Suzukiらはmassive training artificial neural network (MTANN) を用いたFP削減法を提案した⁷⁾. また, 中村らは, 部分空間法を用いてFP削減を目指した⁸⁾. しかし, これらの研究では, 単独ピクセル値を特徴量として用いており, それに伴い, 位置ずれに対応できないなどの問題が生じる可能性がある. 彼らは, あらかじめ手動で位置ずれや回転させた画像を学習データとして作成してこれらの問題の解決を図ったが, 根本的な解決とは言えない.

本研究では, CT画像中の肺結節を診断するための新手法を提案する. 特に, 結節の形状を構成し

ている線分の傾き情報や結節の周辺領域の構造情報を特徴量として抽出することにより，上記で挙げた方法の問題を解決し，かつ，より高いFPの削減率を目指す．

2. 鑑別アルゴリズム

提案手法では，2段階の基準に基づいて陰影を結節か非結節かに鑑別する．はじめに，第1段階では，比較的小さなサイズの関心領域 (region of interest : ROI) 内の陰影の傾き線分情報を用いて鑑別する．次に，第2段階では，第1段階におけるROIを含む周辺領域を新たなROIとし，その構造情報を用いて，第1段階での結節候補を再鑑別する．

2.1 陰影の傾き線分情報を用いた鑑別

傾き線分情報は物体の形状を認識するためには非常に重要である．それにもかかわらず，これまでに結節の傾き線分情報を効果的に用いたCADシステムは提案されていない．本研究では，傾き線分情報を抽出するために，ガボールフィルタを用いた．ガボールフィルタはガウス関数と余弦関数との積で表され，その方向選択性は，顔認識や指紋認識といった，多くの画像認識システムにおいて特徴量抽出機構として利用されている⁹⁾¹⁰⁾．

2.1.1 特徴量抽出

第1段階では，陰影の特徴量を抽出するために，まずROI内の画像 I を以下のような閾値処理により2値化する．

$$I_{\beta}(x, y) = \begin{cases} 1 & I(x, y) \geq \text{mean}(I) + \beta \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

ここで， x, y は画像 I の座標である．次に，傾き θ の線分情報をガボールフィルタを用いて2値画像から抽出する．ガボールフィルタの出力 g は以下の式で

$$\sigma = 10, \quad \lambda = 10, \quad \gamma = 1$$




Fig. 1 Examples of filter output.




Fig. 2 Examples of 4 orientation features.

表される．

$$g(x, y, \sigma, \lambda, \gamma, \theta) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(\frac{2\pi x'}{\lambda}\right) \quad (2)$$

ここで， θ は角度， σ は分散， γ は縦横比， λ は波長である．また， x', y' はそれぞれ以下で表される．

$$x' = x \cos \theta + y \sin \theta, \quad y' = -x \sin \theta + y \cos \theta \quad (3)$$

g の， $\sigma = 10, \lambda = 10, \gamma = 1$ で $\theta = 0^\circ$ と 135° としたときの例をFig.1に図示する．傾き線分情報は原画像 $I(x, y)$ の2値化画像である $I_{\beta}(x, y)$ と $g(x, y, \sigma, \lambda, \gamma, \theta)$ の畳み込み積分で得られる．

$$O_i(x, y) = I_{\beta}(x, y) * g(x, y, \sigma, \lambda, \gamma, \theta_i) \quad (4)$$

ここで， $i = 1, 2, \dots, M_1$ であり， M_1 は抽出する角度の数である．Fig.2は画像に対して4方向のフィルタリングを行った例である．こうして得られた2値画像とそれぞれの方向の傾き画像から3つの特徴量（平均，分散，エントロピー）を計算する．つ

まり, $3 \times (M_1 + 1)$ の特徴量が得られる．そして, これらの $3 \times (M_1 + 1)$ の特徴量を陰影の特徴ベクトル $X = [x_1, x_2, \dots, x_{3(1+M_1)}]^T$ と定義する．

2.1.2 クラスタリング

学習データの特徴ベクトル X に主成分分析を施し, その第 C_1 主成分までを用いて新たな特徴ベクトル X' を得る． K -means 法¹¹⁾ により陰影画像のクラスタリングを行う．本研究で用いた K -means 法のアルゴリズムを以下に示す．

- 1) クラスタの中心 $\mu_1, \dots, \mu_k$ を初期化する．
- 2) それぞれの特徴ベクトル X' を最も距離が小さいクラスタ $\hat{p}$ へ分類する．

$$\hat{p} = \arg \min_{1 \leq j \leq k} D(X', \mu_j) \quad (5)$$

ここで, $D(X', \mu_j)$ は X' と μ_j のユークリッド距離である．

- 3) 分類結果にもとづいて, クラスタの中心を更新する．

$$\mu_j = \frac{1}{n_j} \sum_{i=1}^{n_j} X_i^{(j)} \quad (6)$$

ここで $n_j, j = 1, 2, \dots, k$, はクラスタ j 内の陰影画像の特徴ベクトルの数であり, $X_i^{(j)}$ はクラスタ j 内の i 番目の特徴ベクトルである．

- 4) もしクラスタの中心がどれか1つでも更新されれば 2) へ戻り, それ以外は終了する．

クラスタ数 k の決定にはクラスタ数自動決定法を採用した¹¹⁾．クラスタ数評価値は, 以下で定義される．

$$\rho(k) = \frac{1}{k-1} \sum_{i=1}^{k-1} \max_{i < j \leq k} \left(\frac{\eta_i + \eta_j}{\xi_{ij}} \right) \quad (7)$$

ここで,

$$\eta_j = \frac{1}{n_j} \sum_{i=1}^{n_j} D(X_i^{(j)}, \mu_j) \quad (8)$$

また,

$$\xi_{ij} = D(\mu_i, \mu_j) \quad (9)$$

η_j はクラスタ j 内の特徴ベクトルと中心との平均距離であり, ξ_{ij} はクラスタ i とクラスタ j の距離である．最適クラスタ数 $\hat{k}$ は以下のように定義される．

$$\hat{k} = \min_{1 \leq k \leq L} \rho(k) \quad (10)$$

つまり, K -means 法を用いたクラスタ分析を $k = 1, 2, \dots, L$ まで行い, 最小の $\rho(k)$ を与えるクラスタ数 k を選定する．

2.1.3 候補クラスタの決定

第 C_1 主成分までを用いて, 結節画像に対して P_1 , 非結節画像に対して Q_1 個のクラスタを 2.1.2 節で示した方法で作る．次に, 未学習画像の特徴ベクトルと全てのクラスタのユークリッド距離を計算する．ここで, P_1 個の結節クラスタとの距離を $d_{p_1}^{A1}, p_1 = 1, 2, \dots, P_1$, Q_1 個の非結節クラスタとの距離を $d_{q_1}^{N1}, q_1 = 1, 2, \dots, Q_1$, とする．つまり $(P_1 + Q_1)$ 個の距離が得られる．第1段階での鑑別は結節クラスタとの最小の距離である $d_{p_1^*}^{A1}, p_1^* \in p_1$ と非結節クラスタとの最小の距離である $d_{q_1^*}^{N1}, q_1^* \in q_1$ の比較により行われる．具体的には, もし, $d_1 = d_{p_1^*}^{A1} / d_{q_1^*}^{N1}$ が閾値である α_1 より小さい値をとれば結節候補とし, 大きい場合は非結節とするものである．

2.2 構造情報を用いた鑑別

第2段階では, 陰影を含んだ第1段階でのROIの周辺領域を新たにROIとし, その構造情報を用いて, 第1段階での結節候補を再鑑別する．周辺情報に注目する理由は, Fig.3のように, 結節と非結節では周辺領域の様相が違ふことが多いからである．第1段階における小さなサイズのROIにおいては結節と非結節ではその様相に大きな違いは無いが, 周辺領域の構造にはその違いがあるのがわか

る．これは，結節は比較的孤立的に存在するのに対し，血管などの非結節陰影は他の陰影も近くに存在することが多いためであると考えられる．

構造情報を特徴量として抽出するために，周辺情報のフラクタル次元を新しい特徴量として導入する．フラクタル次元はフラクタルの特性を表す数値であり，物体の構造の複雑さを表す尺度としても用いられる．実際，画像の構造を定量化するフラクタル次元の有用性は多くのCADシステムで報告されている¹²⁾¹³⁾．第2段階での鑑別アルゴリズムを以下，簡単に説明する．

まず，陰影の周辺画像を2値化し，第1段階と同じ方法で平均，分散，エントロピーの3特徴量を計算する．そして，フラクタル次元もボックスカウンティング法¹²⁾¹³⁾を用い計算する．つまり，2値化原画像と M_2 方向の傾き画像の $(1 + M_2)$ 画像に対し，4特徴量を計算する．結果的に，1つの画像に対し $4 \times (1 + M_2)$ 特徴量が得られることになる．学習画像の $4 \times (1 + M_2)$ 特徴量の第 C_2 主成分までを用いて， P_2 の結節クラス， Q_2 の非結節クラスを作る．ここで，最も距離が小さい結節クラスとの距離を $d_{p_2^*}^{A2}$ ， $p_2^* \in p_2 = 1, 2, \dots, P_2$ ，非結節クラスとの距離を $d_{q_2^*}^{N2}$ ， $q_2^* \in q_2 = 1, 2, \dots, Q_2$ ，とする．もし， $d_2 = d_{p_2^*}^{A2} / d_{q_2^*}^{N2}$ が閾値である α_2 より小さい値をとればその未学習画像は結節であると判断し，大きい場合は非結節とする．

3. 実験結果

実験に用いた陰影画像は，Web¹⁴⁾上で公開されているデータベースからダウンロードしたCT画像から得られたものであり，結節に対して97 (学習画像:59, 未学習画像:38) 画像，非結節に対して174 (学習画像:104, 未学習画像:70) 画像を用いた．画像のマトリックスサイズは第1段階，第2段階それぞれ 33×33 と 99×99 である．ガボールフィルタの3つのパラメータ σ, λ, γ は，それぞれ1.5, 2.6, 1と




Fig. 3 Examples of the surrounding images.

した．また，閾値処理による β は第1段階，第2段階共に40とした．クラスタの数 $P_i, Q_i, i \in \{1, 2\}$ や，傾き線分情報を抽出する際の方向の数である M_i ，主成分数 C_i はTable 1に示す． M_i は経験的に決定し， C_i は $\sum_{j=1}^{C_i} u_j > 0.95$ を満たす最小の数を用いた．ここで， u_j は第 j 主成分の寄与率である．

Fig.4に異なる4手法でのROC曲線を示す．ガボールフィルタによる4方向の12特徴量を用いなかった場合，TPが90% のとき，FPは第1段階と第2段階でそれぞれ65%，55% であった．一方で，ガボールフィルタを用いた場合，FPは15% (第1段階)，5% (第2段階)であった．第1段階における65%から15%，第2段階における55%から5%へのFPの減少という鑑別率の向上は，傾き線分情報や周辺情報の導入は肺結節の診断において非常に効果的であることを示唆している．また，MTANN⁷⁾におい

Table 1 Experimental conditions.

Number of	1st stage	2nd stage
Nodule clusters	$P_1=3$	$P_2=2$
Non-nodule clusters	$Q_1=15$	$Q_2=3$
Orientations	$M_1=4$	$M_2=4$
Principal componets	$C_1=5$	$C_2=4$




Fig. 4 Comparison of ROC curves by using (a) conventional, (b) fractal, (c) orientation, and (d) orientation and fractal features.

でも同様の実験を試みたところ同じ条件でFPは35%であった。パラメータや閾値等のより適切な選択によりMTANNの鑑別率の向上の可能性はあるが、提案手法はMTANNと比較して、少なくとも同等以上の鑑別結果を残せたといえる。

4. おわりに

本研究では、CT画像中の肺結節を診断するための新手法を提案した。特に、従来法で大きな値をとっていたFPの低減を目指し、それを実現した。FPが大きいとは、非結節陰影を結節と間違える確率が高いことを意味するが、その低減効果は、医師の負担を軽減するという意味で、臨床的に非常に大きい。この鑑別率向上はガボールフィルタを用いた小さなサイズのROI内の結節の傾き線分情報、また、フラクタル次元を加えた結節の周辺情報を抽出することにより可能となった。現在、実用に向けて、データ数を増やし、システムの信憑性を向上させているところである。

参考文献

- 1) 館野之男, 飯沼武, 松本徹, 他: 肺癌検診のためのX線CTの開発, 新医療, **17-10**, 28/32 (1990)

- 2) 飯沼武, 館野之男, 松本徹, 他: 肺癌検診用CT (LSCT) の基本構想とその事前評価, 日本医放会誌, **52-2**, 182/190 (1992)
- 3) 山本真司, 田中一平, 千田昌弘, 他: 肺癌検診用X線CT (LSCT) の基本構想と診断支援用画像処理方式の検討, 信学論, **76-D-2**, 250/260 (1993)
- 4) K. Takei, N. Homma, T. Ishibashi, M. Sakai, M. Yoshizawa, K. Abe: Computer aided diagnosis system for pulmonary nodules using gabor filter, The 2nd International Symposium on Bio- and Nano-Electronics in Sendai, Book of Abstracts, 53/54 (2006)
- 5) 三輪倫子, 加古純一, 山本真司, 松本満臣, 館野之男, 飯沼武, 松本徹: 可変N - Quoitフィルタを用いた胸部X線CT像からの肺がん病巣候補自動抽出, 信学論, **82-D-II**, 178/187 (1999)
- 6) Y. Lee, T. Hara, H. Fujita, S. Sato and T. Ishigaki: Nodule detection on chest helical CT scans by using a genetic algorithm, Proc. of IASTED International Conference on Intelligent Information Systems, 595/604 (1997)
- 7) K. Suzuki, S. G. Armato III, F. Li, S. Sone, K. Doi: Massive training artificial neural network (MTANN) for reduction of false-positives in computerized detection of lung nodules in low-dose computed tomography, Med.Phys, **30-7**, 1602/1617 (2003)
- 8) 中村嘉彦, 深野元太郎, 滝沢穂高, 水野慎士, 山本真司, 松本徹, 曾根脩輔, 高山文吉, 小山真弘, 和田慎一: 肺結節陰影の位置ずれや回転を考慮した部分空間法によるX線CT画像の認識, 信学技報, **MI2004-102**, 119/124 (2005)
- 9) K. C. Chung, S. C. Kee, S. R. Kim: Face recognition using principal component analysis of gabor filter responses, Proceedings. International Workshop on 26-27 Sept, 53/57 (1999)
- 10) C. J. Lee, S. D. Wang: A Gabor filter-based approach to fingerprint recognition, IEEE Workshop on 20-22 Oct, **52**, 371/378 (1999)
- 11) C. W. Ngo, T. C. Pong, H. J. Zhang: On clustering and retrieval of video shots through temporal slice analysis, IEEE Trans. Mlt., **4-4**, 446/458 (2002)
- 12) S. Kido, J. Ikezoe, H. Naito, S. Tamura, S. Machi: Fractal analysis of interstitial lung abnormalities in chest radiography, Radiographics, **15**, 1457/1464 (1995)
- 13) T. Ishida, K. Yamashita, A. Takigawa, K. Kariyaet, H. Itohal: Trabecular Pattern Analysis using Fractal Dimension, Japanese Journal of Applied Physics **32-1-4**, 1867/1871 (1993)
- 14) National Cancer Imaging Archive (NCIA), <https://imaging.nci.nih.gov/ncia/faces/baseDef.tiles>