

候補領域抽出と機械学習によるポリープの自動検出

Automatic Polyp Detection Using Extraction of Candidate Region and Machine Learning

岩堀 祐之¹ 服部 晃¹ 福井 真二² 春日井 邦夫³

Yuji Iwahori Akira Hattori Shinji Fukui Kunio Kasugai

¹ 中部大学 工学部
Chubu University

² 愛知教育大学 教育学部
Aichi Univ. of Educ.

³ 愛知医科大学
Aichi Medical Univ.

1 はじめに

今日、医療の現場において管状の器具の先端にカメラのついている内視鏡カメラを用いた診察は盛んに行われている。それらの診察では、胃や大腸など様々な部位に対して行われ、出血、炎症、腫瘍などの異常部の発見を主な目的としている。その異常部の一つにポリープがある。ポリープというものは、一般的に隆起性病変全般を形態的に表現するものであり、それらは後にガン化する可能性がある。ガン化を防ぐため、正確に早期発見することは重要であるが、内視鏡を用いた診察で見つかるポリープの大きさや形状は多種多様であり、診察には多くの経験と時間を必要とするため見落としは起こりうる。

それらを防ぐ目的として、当研究室では文献[1]を提案している。文献[1]では内視鏡画像に対してヘシアンフィルタを適用することにより、塊状構造を持つ輝度パターンを強調させた画像を作成し、ポリープ候補領域として画像中からポリープのおおまかな位置を特定した後に特徴抽出を行い、ポリープ候補領域を識別器により分類することでポリープの自動検出を行っている。これによりポリープが撮影される場所に依存せず、多種多様なポリープの自動検出を可能にしている。また、分類問題を簡略化することにより、分類精度の向上を図っている。

しかし、文献[1]ではポリープ候補領域の大きさにより、ポリープの特徴を上手く抽出できない場合がある。本稿では文献[1]を元に改良を行い、有効性が確認されたエッジ特徴量を利用しポリープの自動検出を行う。

2 ポリープ候補領域の検出

本稿では、ポリープの特徴であるふくらみ特有の輝度情報を持つ領域をポリープ候補領域として検出後、それらの領域からHOG(Histograms of Oriented Gradients)[3]特徴量の抽出を行い、ポリープの自動検出を行う。

ポリープ候補の検出方法としては、内視鏡画像に対しヘシアンフィルタを施すことにより、ふくらみが持つ輝度情報を強調させた画像を作成し、セグメンテーションによりポリープ候補領域を検出することで行う。

2.1 ヘシアンフィルタによる強調画像作成

文献[2]では、表1に示すヘシアン行列の固有値 λ_1, λ_2 の対応表に基づき管状構造を持つ領域の値を高く出力する計算式を用いて、画像に含まれる血管領域を強調させた画像を作成している。それに対し文献[1]では、 λ_1, λ_2 を用いた計算式を塊状構造の領域でのみ値が大きくなるように与えることで、塊状構造を強調するヘシアンフィルタを作成している。

次に、塊状構造を強調するヘシアンフィルタの処理の流れを次に示す。

Step1 Scale s (ガウス関数の幅)をもつガウス関数 $G(x, y)$ を作成する。

Step2 G の x 方向の微分 $G_x(x, y)$ と y 方向の微分 $G_y(x, y)$ を求め、さらに G_x の x 方向の微分 $G_{xx}(x, y)$ と y 方向の微分 $G_{xy}(x, y)$ と G_y の y 方向の微分 $G_{yy}(x, y)$ を求める。

- Step3** 入力画像 $L(x, y)$ と $G_{xx}(x, y), G_{xy}(x, y), G_{yy}(x, y)$ の置み込みにより、微分 $L_{xx}(x, y)$ と微分 $L_{xy}(x, y)$, 微分 $L_{yy}(x, y)$ を求める.
 $L_{xx}(x, y) = L(x, y) * G_{xx}(x, y)$ (1)
 $L_{xy}(x, y) = L(x, y) * G_{xy}(x, y)$ (2)
 $L_{yy}(x, y) = L(x, y) * G_{yy}(x, y)$ (3)

Step4 求められた微分値を元にヘシアン行列を求める.

$$H = \begin{bmatrix} L_{xx} & L_{xy} \\ L_{xy} & L_{yy} \end{bmatrix} \quad (4)$$

- Step5** ヘシアン行列 $H(2 \times 2)$ の固有値 ($\lambda_1 < \lambda_2$) を求める.

- Step6** 各点 (x, y) での強度を以下の式で計算する.

$$I(x, y) = (\lambda_1(x, y)^2 + \lambda_2(x, y)^2) * (1 - \left(\frac{\lambda_1(x, y)}{\lambda_2(x, y)}\right)^2) \quad (5)$$

表 1: ヘシアン行列の固有値の対応表
($H=high, L=low, N=noisy$)

λ_1	λ_2	方向付けパターン
N	N	noisy,no preferred direction
L	H_-	tubular structure(bright)
L	H_+	tubular structure(dark)
H_-	H_-	bolb-like structure(bright)
H_+	H_+	bolb-like structure(dark)

図 1 の画像に対しヘシアンフィルタを用いて塊構造領域を強調させた結果を図 2 に示す.



図 1: 元画像

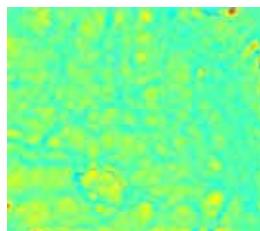


図 2: 強調画像

3 HOG 特徴量の抽出

文献 [1] では色特徴量とエッジ特徴量を抽出している. しかし, ポリープ候補領域の大きさや形が定まって

いない. 抽出する HOG 特徴量の次元数を一定にするために, 候補領域の大きさを一定サイズのパッチにダウンサンプリングを行っている. そのため候補領域の大きさによっては局所的なエッジ特徴量ではなく, 大域的な情報となってしまい, ポリープの情報を上手く抽出することができない場合がある. 本稿ではポリープの微小な輝度勾配情報を抽出するために, 候補領域の大きさに依らず HOG 特徴量のパラメータを一定とし, 局所特徴量を抽出する.

3.1 HOG 特徴量

HOG 特徴量とは局所領域の輝度の勾配方向をヒストグラム化したもので, 人検出においてその特徴量の有効性が確認されている. 内視鏡環境では, ポリープ領域と非ポリープ領域において, 色の変化は少ない. またポリープがきれいな橢円形として映らない場合もある. HOG 特徴量では局所的な輝度の勾配方向を抽出するため, 捉えづらいエッジであっても特徴量を抽出することができる.

3.2 HOG 特徴量の算出

まず入力画像の各ピクセルの輝度値 $I(x, y)$ から勾配強度 m と勾配方向 θ を算出する.

$$m(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (6)$$

$$\theta(x, y) = \tan^{-1} \frac{f_y(x, y)}{f_x(x, y)} \quad (7)$$

$$\begin{cases} f_x(x, y) = I(x+1, y) - I(x-1, y) \\ f_y(x, y) = I(x, y+1) - I(x, y-1) \end{cases} \quad (8)$$

次に, 算出した勾配強度 m と勾配方向 θ を用いて $p \times p$ ピクセルからなるセルの領域ごとに重み付き勾配方向ヒストグラムを作成する. 算出される勾配方向 θ は向きを N 方向に量子化し, 勾配方向ごとに勾配強度 m を加算することで, 各セルの重み付き勾配方向ヒストグラムを作成する.

最後に HOG 特徴量の正規化を行う. $q \times q$ セルからなるブロック内の HOG 特徴量の総和を分母とし, HOG 特徴量の正規化を行う.

$$v(n) = \frac{v(n)}{\sqrt{\sum_{k=1}^{q \times q \times N} v(k)^2} + \epsilon} \quad (9)$$

ここで, $v(n)$ はある n 番目の HOG 特徴量, ϵ は 0 割れを防ぐ定数である. このブロックを入力画像に対してオーバーラップをさせながら移動をさせることで, 入力画像に対する HOG 特徴量が算出される. そのため, 一つのセルは複数回正規化が行われることとなる.

例えば入力画像のサイズが $h \times w$ だとすると, HOG 特徴量の次元数は $(\frac{w}{p} - q + 1)(\frac{h}{p} - q + 1) \times q^2 \times N$ となる.

4 学習機による分類

HOG 特徴量は次元数が非常に大きくなる. そのため文献 [1] のように特徴選択を行い, SVM による分類を行うことはできない. 本稿では特徴次元数が大きくても効率的に分類することができる Real AdaBoost と Random Forests[4] を用い, 比較実験を行った.

4.1 Random Forests

Random Forests はブースティングと違い, 相関の低い弱識別器を組み合わせることで高精度な識別器を構築するバギングにより学習を行う. Random Forests では弱識別器として決定木を使用する.

4.2 Random Forests の構築

学習データ全体を \vec{S} とすると決定木ごとに学習データ $\vec{S}_0 \in \vec{S}$ をランダムに選択し, 学習する. この時学習データ \vec{S}_0 は互いにデータの重複を許す. 学習データ \vec{S}_0 のノード j における分割閾値を式 (10) とする.

$$h(\vec{v}, \theta_j) \in \{0, 1\} \quad (10)$$

\vec{v} がノード j に到達したデータ, θ が分割閾値を決定するパラメータであり, $\theta = (\phi, \psi, \tau)$ とする. ϕ は d 次元のデータ \vec{v} から, 幾つかの特徴を抽出するフィルタ, ψ は分割基準, τ は分割を行う際の閾値を示す. この決定木の成長をデータの分割ができなくなるまで行う.

これら弱識別器の多数決が, 未知データを入れた際の出力となる.

5 検出結果の統合

内視鏡画像に対してポリープの検出を適用すると, 複数の検出窓においてポリープの検出がなされる. 本稿では k-means 法を改良した k-means++法を使用し, 結果の統合を行った.

5.1 k-means++法

k-means 法はクラスタ中心を見つけるアルゴリズムである. クラスタ中心とはクラス内分散を最小化する点であり, 言い換えるとクラス内のそれぞれのデータ点との距離の二乗和を最小化する点である. しかし, k-means 法の結果はクラスタ中心の初期点に依存してしまい, 最悪の結果も保証されていない. その k-means 法を改良したものが文献 [5] の k-means++法である. k-means 法の初期点は互いに離れていたほうが良い結果となる. そのため, まずランダムにデータを選び 1 つ目のクラスタ中心とする. その後, 全てのデータとその最近傍のクラスタ中心との距離に比例した確率で, クラスタ中心に選ばれていないデータ点をクラスタ中心としていく. こうして選ばれたクラスタ中心を初期点として用い, k-means 法を適用する.

本稿では画像中にどれだけポリープと検出されるかがわからない. そのためクラスタ間の互いの距離が閾値以上になるまで k の数を減らしつつ, k-means++法を適用し続ける.

6 実験

本稿で提案した手法の有効性を示すために, 内視鏡診断に用いられる画像に対して実験を行う.

6.1 データセット

実験に用いる内視鏡画像は, 小さいもので約 1000 画素, 大きい物で約 13000 画素の大きさでポリープが映っている内視鏡画像 156 枚を使用する. 解像度は約 1000×900 である. 1 枚の内視鏡画像から, 手動で作成したマスク画像を用いてポリープ上から特徴抽出した Positive sample を 1 個, 非ポリープ上から特徴抽出した Negative sample を 4 個作成する. また内視鏡環境

において上下左右に意味はなく、ポリープの映り方は多種多様だと考えられる。そのため、内視鏡画像を0度から160度まで20度づつ回転させ、データセットを増やした。従ってPositive sampleは1404個、Negative sampleは5616個となる。Positive sampleのうち75%、つまり1053個をランダムに選択し学習データセットとして使用し、残りの351個をテストデータとして使用する。Negative sampleについては5616個からランダムに1053個を学習データセットとして使用し、残りをテストデータとして使用する。Real AdaBoostの学習パラメータとして、弱識別器の数を6000、特徴量の量子化を100段階とした。Random Forestsの学習パラメータとして、決定木の数を5000、決定木で使用する特徴次元数を151とした。

6.2 実験結果

実験結果を表2,3に示す。Sensitivity(Sens)がPositive sampleにおける正答率、Specificity(Spec)がNegative sampleにおける正答率を表している。試行回数(T)それぞれにおいて、学習データはランダムに選択している。

表2: Real AdaBoost

T	Sens[%]	Spec[%]
1	100	97.7
2	99.1	96.5
3	99.1	57.2
4	100	97.4
5	98.5	97.1
6	100	96.8
7	98.8	97.7
8	98.2	99.1
9	99.1	99.1
10	100	97.4

表3: Random Forests

T	Sens[%]	Spec[%]
1	100	98.4
2	100	98.1
3	100	98.2
4	100	98.4
5	100	98.1
6	100	98.3
7	100	98.2
8	100	98.4
9	99.7	97.9
10	100	98.4

どちらの識別器においても高い認識率を確認することができた。特にRandom Forestsではポリープをほぼ見逃すことなく検出している。また内視鏡画像を回転させてデータセットを作成しているため、ポリープの映り方による認識率の変動に対して、信頼性があるといえる。図3にRandom Forestsによりポリープ自動検出した結果、図4にk-means++法により結果を統合した結果を示す。ポリープ候補領域は内視鏡画像の10.3%であった。

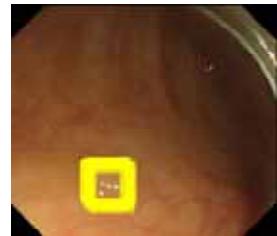


図3: 統合前

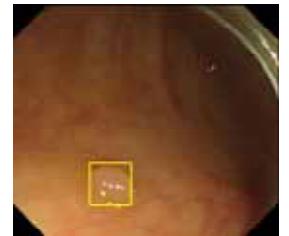


図4: 統合後

7 おわりに

本稿ではポリープ候補領域を強調し、候補領域内でHOG特徴量によるポリープの自動検出を行った。識別器としてRandom Forestsを用いることにより、高い認識率を残すことができた。また内視鏡画像に対し、少ない計算コストでポリープを自動検出できることを確認した。今後の課題としてNegative sampleの質を高め、検出結果を向上させることが考えられる。

謝辞 本研究の一部は中部大学研究費および科研費補助金基盤研究(C)(#26330210)による。ここに感謝申し上げる次第である。

参考文献

- [1] 篠原孝幸, 岩堀祐之, 福井真二, 春日井邦夫, “ヘシアンフィルタを用いた内視鏡画像からのポリープ自動検出”, 電子情報通信学会技術研究報告, 医用画像, Vol.111, No.389, pp.305-310, 2012.
- [2] Alejandro F. Frangi, Wiro J. Niessen and Koen L. Vincken, “Max A. Viergever, Multiscale vessel enhancement filtering”, in Proc. 1st MICCAI, pp.130-137, 1998.
- [3] N. Dalal *et al*, “Histograms of Oriented Gradients for Human Detection”, CVPR, 2005.
- [4] Leo Breiman, “Random Forests”, Machine Learning, Vol.45, No.1, pp.5-32, 2001.
- [5] David Arthur and Sergei Vassilvitskii, “k-means++: The Advantages of Careful Seeding”, In Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms, pp. 1027-1035, 2007.