

医療診断支援のための内視鏡画像の分類と 大きさ・形状の復元

岩堀祐之, 宇佐美裕康*, 大音 翼*, 村田征隆*,

小笠原尚高**, 春日井邦夫**

Classification and Size & Shape Recovery from Endoscope Image for Supporting Medical Diagnosis

Yuji Iwahori, Hiroyasu Usami*, Tsubasa Ooto*, Masataka Murata*,
Naotaka Ogasawara** and Kunio Kasugai**

This paper proposes a method to detect and the classify the polyp from endoscope image, and futher proposes a method to recover the size and shape of polyp for the purpose of supporting medical diagnosis. Here, polyp detection is proposed using CNN (Convolutional Neural Network) which is learned for the general object recognition and additional learning is introduced using the Fine-Tuning which is fitted for the polyp detection. This Fine-Tuning enables the suitable detection in the endoscope environment which does not sufficient number of endoscope images. After the polyp detection, malignant or benign of polyp is judged to the proposed approach using three different kinds of endoscope images consisting of white light image, dyed image and narrow band image (NBI). Seven kinds of Support vector machine classifiers are learned for the CNN feature vectors obtained from each image input and the approach shows that voting processing of each output of SVM provides the higher classification ability. Shape recovery of polyp first introduces the analysis of blood vessel and tries to find the corresponding points between two frames. The paper shows the blood vessel detection is used as the key to the shape and size recovery of polyp. The approach is demonstrated via experiments using actual endoscope images.

Keywords : *Endscope Image, Polyp Detection, Polyp Classification, Polyp Shape and Size Recovery, Convolutional Neural Network, Fine-Tuning*

1. はじめに

内視鏡から得られた人体内部の画像を用いて、胃壁などの形状復元を行うことで、腫瘍などの形状に関する定量的な情報を得ることが可能になる。内視鏡画像診断の立場からは通常内視鏡でポリープ検出、分類、形状復元を行う手法が望ましい。

本研究では、医療診断支援を目的として、内視鏡画像からポリープ検出を行う検出手法、検出したポリープに対して良性・悪性の分類を行う分類手法、さらには分類の困難なポリープに対して、大きさ・形状復元を行う形状復元手法を提案する。

* 大学院学生 ** 愛知医科大学 医学部 消化管内科

ポリープ検出手法として、これまで画像を固定長の矩形 (パッチ) で分割するパッチベースの手法が提案されている^{1), 2), 3)}が、固定長のパッチベース手法では、検出精度はパッチサイズに依存してしまい、ポリープの大きさによっては検出できないといった問題がある。

パッチベース以外の手法として文献^{4), 5), 6)}がある。文献⁴⁾では高周波成分を除去した内視鏡画像に対しヘシアンフィルタを施すことにより、塊状構造を持つ領域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の検出を行うが、ヘシアンフィルタを用いたポリープ候補領域の検出ではポリープ部分以外でも多くの領域が候補領域として誤検出されてしまう問題がある。

文献⁵⁾では画像中の輝度値が周囲に比べて小さくなっている谷部分をエッジとして抽出し、そのエッジを基にポリープである可能性が高い領域に対して尤度マップを作成し、ポリープの検出を行う。しかし、この手法では血管もエッジとして抽出してしまうため、血管がポリープのエッジと似た形状の場合や血管が多い画像では血管がノイズとなり検出精度が低減する。文献⁶⁾では、ガウス関数のスケール σ を変動させながら畳み込み処理を行い、モルフォロジーグラジエント処理によってエッジを抽出することで、血管エッジ抽出を抑制しながらポリープのエッジ情報を抽出し尤度マップを作成している。そして、尤度の高い箇所を候補領域として、そこから取得した HOG 特徴量と Random Forest を用いてポリープを検出している。

本研究では、さらなるポリープ検出精度向上を目的として、一般物体認識を目的として学習を行なった Convolutional Neural Network (以下, CNN)⁷⁾を利用し、内視鏡画像を用いて Fine-Tuning を行うことで、十分な学習データを用意できない内視鏡画像において、CNN による高精度なポリープ検出を実現する。

ポリープ分類手法として、超拡大内視鏡で撮影された画像を用いることで高精度なポリープの診断を行う文献⁸⁾が提案されている。

しかし、超拡大内視鏡は通常の内視鏡よりも高倍率であり、細胞レベルでの診断を可能とするが、導入されている医療機関は限られており、一般的な内視鏡診断で用いられるまで普及していない。そのため、一般的な診断で用いられている通常の内視鏡での高精度なポリープ良性・悪性分類を可能とする必要がある。

一般的な内視鏡で撮影することのできる画像には、白色光源・染色・Narrow Band Imaging(以下, NBI)の三種類の画像がある。この三種類の画像はそれぞれ違う特徴を持ち、ポリープの種類によって良性・悪性判断時に有効な情報が得られる画像種別は異なる。一般的な内視鏡は超拡大内視鏡に比べ広範囲が撮影されるため、撮影された画像がポリープ以外の領域を多く含むことがあり、良性・悪性の判断時に効果的な情報が得られない場合がある。本研究では、はじめに先に提案するポリープ検出手法で検出したポリープ領域を対象として、内視鏡で撮影可能な三種類の画像から得られる特徴量を利用し、高精度な分類診断を実現するポリープ分類手法を提案する。

ポリープ形状復元手法として、画像の陰影情報から物体の形状を復元する Shape from Shading(以下, SFS)⁹⁾ベースとし、ポリープの形状復元を行う手法が提案されている^{10), 11), 13)}。SFS を用いた形状復元手法では、内視鏡カメラから物体までの奥行き、物体表面の反射係数などの光学的制約式を利用するための初期パラメータが必要となる。文献¹⁰⁾では内視鏡画像内に含まれる医療用縫合糸の太さを参照し、撮影する二枚の内視鏡画像においてフレーム間での縫合糸の太さの違いから内視鏡カメラの移動量を幾何学的に計算することで初期パラメータを推定している。文献¹¹⁾では縫合糸に代わる参照物体としての血管を応用することで初期パラメータ推定時の制約条件を緩和している。文献¹¹⁾では血管を検出する際に、HSV 表色系を用いて最頻値や最頻値に近い値を計算し、血管の検出を行っているが、血管と腸内壁で明確な違いがない場合では対応できず、血管以外の不要な領域も同時に検出してしまう。本研究では、眼球の血管領域抽出を目的とする Frangi Filter¹⁵⁾を腸の血管領域抽出に応用した手法¹⁶⁾を利用し、血管領域の抽出を行う。また、血管の太さを参照してカメラの移動量を推定する場合、二枚の画像間での正確な対応点を得ることが重要となる。文献¹¹⁾では、一枚目の血管領域に対応する二枚目の血管領域検出にテンプレートマッチングを用いている。しかしテンプレートマッチングの問題点として画像の回転などの変化に弱く、肉壁や内視鏡の動きに伴う回転が含まれやすい内視鏡環境においては不向きであり、

画像によっては正しい移動先を検出できない場合がある。本研究では、血管領域の検出を行った画像に対して血管の構造解析を行い、構造情報をグラフ化し、二枚の画像間でのグラフの対応関係を求めることによって類似度の高い領域の検出を実現し、画像の変化や回転に対応できる移動先の検出を行うことで汎用性の向上を目的とした手法を提案し、内視鏡環境においてより頑健な形状復元を実現する。

以下、提案するポリープ検出手法、ポリープの良性・悪性分類手法、ポリープの大きさ・形状復元手法についてそれぞれ述べる。

2. Fine-Tuning と尤度マップを用いたポリープ検出

提案手法では、はじめに内視鏡画像に含まれる鏡面反射成分除去を行い、ポリープのエッジ情報をもとに尤度マップの作成する。そして、一般物体認識用のデータセットで事前学習済みの CNN を内視鏡画像を用いて Fine-tuning することで、ポリープ検出用 CNN を構築し、作成した尤度マップにおいて尤度の高い箇所を候補領域としてポリープ検出を行う。また、ポリープ検出は pre-trained network 得られる特徴量を利用する検出手法、pre-trained network の全層を Fine-tuning した CNN を構築する検出手法、全結合層のみ Fine-tuning を行う検出手法を試みた。提案手法の処理手順は以下の通りである。

- Step.0 ポリープ画像と非ポリープ画像を用いて、CNN から得られた特徴量を SVM に学習させる。また、別の識別器として CNN を Fine-Tuning する。
 - Step.1 入力画像に対してノイズとなる鏡面反射成分の除去を行う。
 - Step.2 ノイズ除去後の画像に対してモルフォロジーグラジエント処理を行い、エッジ抽出を行う。
 - Step.3 入力画像に対して画像ピラミッドを構築する。
 - Step.4 画像ピラミッド中の最も低解像度の画像に対し、文献⁶⁾の方法により尤度マップを作成する。
 - Step.5 一段高い解像度レベルの画像ピラミッドに、作成した尤度マップをリサイズし、尤度の高い箇所のみで再度、尤度マップを作成する。この処理を画像ピラミッドの最上位のレベルまで繰り返す。
 - Step.6 尤度の最大値の 8 割以上の座標を取得し、k-means++によってクラスタ中心の座標を算出する。
 - Step.7 中心座標から尤度を計算する際に用いた円によるフィッティング処理から、最もエッジ強度の高い箇所までの距離を求める。
 - Step.8 中心座標に対して求めた距離の 2 倍の大きさの矩形を作成し候補領域とする。
 - Step.9 候補領域を入力として、各ポリープ検出手法によりポリープを検出する。
- 以下、処理の詳細を述べる。

2.1. 鏡面反射成分の除去

内視鏡カメラは腸内撮影時に白色光源を用いており、内視鏡画像は画像中に白色の鏡面反射成分が存在する場合が多い。これら鏡面反射成分は尤度の算出ならびにマップ作成時の障害となり得る。そのため、正確なポリープ検出を行うためには鏡面反射成分除去が重要である。提案手法では文献⁶⁾同様に文献⁹⁾により鏡面反射成分を抽出し、除去後インペインティングにより補間することで鏡面反射成分の除去を行う。内視鏡画像に対して鏡面反射成分を除去し、補間を行った結果を図 1 に示す。




Figure 1. 鏡面反射成分除去

2.2. エッジ抽出

提案手法では、内視鏡画像に発生しやすいブレや表面テクスチャ等のノイズによるエッジ検出時の影響を軽減するために、ガウス関数式 (1) に含まれるスケール σ を変動させながら 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 G_y の y 方向の微分 $G_{yy}(x, y)$ を求める。そして、入力画像 $G_{xx}(x, y)$ 、 $G_{yy}(x, y)$ の畳み込みによって求められた各座標の値から x 方向と y 方向の内高い方の値をエッジ画像の値として用いる。そしてスケール変動終了後に算出された全てのエッジ画像に対してモルフォロジーグラジエント処理を行うことでエッジを検出する。

$$G(x, y) = \frac{1}{2\pi\sigma} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (1)$$

エッジを検出する際に尤度算出に用いるエッジ強度 E を算出する。エッジ強度 E はモルフォロジーグラジエント処理によって算出されたエッジに対して、各スケール σ で求められたエッジ画像を加算した値を乗算することで求められる。

2.3. 尤度マップの作成

文献⁵⁾はポリープのエッジが丸みを帯びていることに着目し、エッジの形状と強度を基に尤度マップを作成している。また、文献⁶⁾では文献⁵⁾の尤度マップに対して色の明暗を用いた重みを付加することでポリープ以外の箇所値が小さくなるようにしている。尤度マップ算出の概念図を図2に示す。




Figure 2. 概念図

次に、尤度マップの作成手順を以下に示す。

注目画素 p を中心とした任意の大きさの円を作成し、円を任意の角度で分割する。図 2(a)に示すように分割した領域 S ごとに式(2)によってエッジ強度 E の最大値 S_i^{max} を求める。

$$S_i^{max} = \max_{S_i} \quad (2)$$

求めた S_i^{max} の位置 $p_{S_i^{max}}$ を求め、図 2(b) に示すように p と $p_{S_i^{max}}$ のユークリッド d 距離 d_i を計算する。式(3)によって領域 S_i とその前後の領域での距離 d の中央値 $\tilde{d}_i$ を求める。

$$\tilde{d}_i = \text{median}(d_j) \quad j \in \left[i - \frac{l-1}{2}, \dots, i + \frac{l-1}{2} \right] \quad (3)$$

ここで、 l は中央値を求める際に用いる領域の数である。距離 d と $\tilde{d}_i$ を用いて重み γ_i を式(4)より求める。

$$\gamma_i = \frac{1}{1 + \frac{|d_i - \tilde{d}_i|}{\tilde{d}_i}} \quad (4)$$

ここで、 γ_i は注目画素 p と最大値 S_i^{max} の距離 d が連続する領域で類似する場合、その最大値 S_i^{max} はポリープエッジの一部であると判断して大きくなる。次に領域毎に求めた距離 d_i より距離が大きい画素の R 成分の値($R_{d_i} > d_i$)の平均と注目画素の R 成分の値(R_p)を用いて α_i を式 (5)より求める。

$$\alpha_i = \frac{R_p}{\text{mean}(R_{d_i} > d_i)} \quad (5)$$

求めた α_i に対してシグモイド関数式(6)を適用することで重み α'_i を求める。

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (6)$$

α'_i は注目画素の輝度値が周囲の平均輝度値より大きい場合に大きくなり、小さい場合は小さくなる。内視鏡画像でのポリープはエッジの内側は明るく、外側は暗くなっているため、重み α'_i が大きい場合はポリープのエッジである可能性が高く、小さい場合は内壁のエッジである可能性が高い。

次に式(7)によって最大値 S_i^{max} と距離の重み γ_i 、色の重み α'_i を掛け合わせるにより $\hat{S}_i^{max}$ を求める。

$$\hat{S}_i^{max} = \alpha'_i \gamma_i S_i^{max} \quad (7)$$

最後に式(8)によって領域ごとに求めた $\hat{S}_i^{max}$ の中央値 MS_p を求める。

$$MS_p = \text{median}_i(\hat{S}_i^{max}) \quad i \in [1, \dots, n] \quad (8)$$

ここで n は円の分割数である。求めた MS_p を注目画素に対応する尤度マップの値とする。

2.4. 尤度マップ作成のコスト削減

提案手法では画像ピラミッドを用いて尤度マップ作成のコスト削減を行う。まず始めに入力画像に対して画像ピラミッドを任意の階層で作成し、一番解像度が低い画像に対して尤度マップを作成する。この段階で作成されるマップはポリープ上だけではなくポリープ周辺の画素でも尤度が高くなり、大よその位置が掴める程度のマップとなる。次に、図 3 の様に作成された尤度マップの内、尤度が閾値を超えている箇所のみを 1 段階解像度の高い画像に対して尤度の算出を行い、尤度マップを作成する。このとき作成されるマップは先ほど作成されたマップと比べ、ポリープ周辺の尤度が高くなるのを抑えられたより信頼度の高いマップとなる。この処理を一番解像度の高い画像に対して行うまで繰り返して段階的に尤度マップを作成することで計算コストを削減し、最終的な尤度マップを作成する。




Figure 3. コスト削減法概念図

2.5. ポリープ候補領域の抽出

提案手法では作成した尤度マップから最大値の 8 割以上の値を示す画素の座標に対して **k-means++** 法を用い、クラスタ内の中心を求め、中心座標から矩形を作成し候補領域とする。これにより、1 つのポリープに対して候補領域が多数検出されることを抑制する。候補領域の大きさは求めた中心画素と尤度マップ作成時に求めた判定円内の最大エッジ強度までの距離 d_{max} を 2 倍にした $2d_{max}$ とした。

候補領域の概念図を図 4 に示す。




Figure 4. 候補領域概念図

2.6. CNN の Fine-Tuning によるポリープ検出

取得可能なサンプルに偏りが生じるなど、十分な学習データを用意できない内視鏡画像において、提案手法では、一般物体認識を目的として学習を行なった VGG16¹⁹⁾ を利用し、内視鏡画像を用いて Fine-Tuning を行うことで、ポリープ識別器を構築する。

Fine-Tuning に用いるデータセットは、CVC-Clinic²⁰⁾ を用いた。CVC-Clinic データセットの概要を表 1

に示す. 学習画像はポリープ画像と非ポリープ画像で構成し, CVC-Clinic データセットの画像が 612 枚と少ないため, 学習時には回転やランダムな垂直方向への移動とズームを行う DataAugmentation 処理を行い, 学習画像枚数を増やした.

Table1. CVC-Clinic データセットの概要

Institution	Content	Device
HospitalClinic,Barcelona,Spain	612SD frames(388×284) From 31 sequences	Olumpus Q160AL and Q165L, Exera 2 videoprocesser

2.7. 評価実験

提案手法の有効性を確認するために評価実験を行った. まず始めにテスト画像に対して作成した尤度マップを図 5 に示す. このとき尤度マップを作成する際に用いた円の半径を 160 画素, 円の分割数を 24 分割とした.




Figure 5. 尤度マップ作成例

図 5 からポリープ上の尤度が高くなるようなマップが作成されていることが確認できる.

次に, CNN の Fine-Tuning によるポリープ検出手法の評価実験結果について述べる. CNN のモデルには一般物体認識のためのデータセットである ImageNet を学習済みの VGG16 を用いた. VGG16 は 13 層の畳み込み層と 3 層の全結合層で構成されており, 畳み込み層 5 層, 全結合層 3 層の AlexNet²⁴⁾と比べてより深いネットワークとなっている. さらに VGG16 では各畳み込み層のフィルタのサイズが 3×3 となっており, 2 層か 3 層の畳み込み層の後にプーリング層を配置している. また, 畳み込み層のフィルタサイズが AlexNet の 5×5 より小さくなっていることでパラメータの数を抑えることができています. 学習時にはバッチサイズを 32 とし, 学習の最適化方法には Adam²¹⁾を用い, これらの実装には Tensorflow をバックエンドとした Keras を用いた. また, 学習済みネットワークに対して Fine-Tuning は全層を対象とする場合, Conv5+全結合層のみを対象とする場合で行い精度評価を行なった. 学習結果を図 6 に示す. 図中の青いグラフが全層 Fine-Tuning, 赤いグラフが Conv5+全結合層のみ Fine-Tuning した結果となっている. また, 図 6(a)の縦軸が accuracy, 図 6(b)の縦軸が loss となっており, 横軸は共にエポック数となっている. 図 6 から, 学習時点では全層 Fine-Tuning した場合がより高精度であることがわかる.




Figure 6. 学習結果

次に、ETIS-LARIB²²⁾をデータセットとして用いた場合の実験結果を示す。

ETIS-LARIB データセットの概要は表 2 に示す通りである。

Table2. ETIS-LARIB データセットの概要

Institution	Content	Device
LariboisiereHospital, Paris, France	196HD frames(1225×966) From 34 sequences	Pentax 90iseries, EPKi 7000, videoprocessor

次に実験結果を表 3 に示す。表 3 から全層 Fine-Tuning した場合、もっとも高精度でポリープ検出ができていたことがわかる。このことから、文献¹²⁾と同様、学習画像の少ない内視鏡画像の場合においても Fine-Tuning の有効性を確認することができる。

Table3. Classification result[%]

	<i>Sensitivity</i>	<i>Specificity</i>	<i>Accuracy</i>
全層 Fine-Tuning	81.14	25.67	60.20
Conv5+全結合層	80.32	22.97	58.67

今回の実験では *Specificity* が低く過検出気味の結果が得られている。

その原因としては、尤度マップの作成時の候補領域が大きく、学習データが少ない場合では十分な Fine-Tuning が実施できず、CNN による分類精度が低減することが挙げられる。この問題を解決するためには、より少ない学習データに有効なネットワーク構造の検討が今後の課題として挙げられる。

3. 複数種類の内視鏡画像からの投票処理によるポリープ分類

一般的な内視鏡は超拡大内視鏡に比べ広範囲が撮影されるため、撮影された画像がポリープ以外の領域を多く含むことがあり、良性・悪性の判断時に効果的な情報が得られない場合がある。そのため、提案手法では、ポリープ検出手法により検出した領域を対象としてポリープの良性・悪性の分類を行う。はじめに、内視鏡で撮影可能な白色光源・染色・NBI の三種類の画像に対してラベル付けを行い、その後、CNN を特徴抽出器として活用し、各種類の画像特徴量を抽出する。そして、画像特徴量を入力として、白色光源・染色・NBI の三種類の組合せにより複数の Support Vector Machine(以下、SVM)を構築し、

各 SVM でポリープの良性・悪性を分類し、それぞれの分類結果を投票処理によって統合することで、最終的な分類結果を算出する。

提案手法の流れを以下に示す。

Step.0 内視鏡画像のラベル付け

Step.1 各種類の画像をそれぞれ入力とした CNN によって特徴抽出

Step.2 CNN で得られた特徴量から複数の SVM 識別器の構築

Step.3 複数の SVM の分類結果から投票処理によって最終的な結果の算出


3.1. 内視鏡画像のラベル付け

内視鏡で撮影可能な内視鏡画像には、白色光源(図 7(a))・染色(図 7(b))・NBI(図 7(c))がある。これらの内視鏡画像は、以下のような特徴を持っている。


白色光源： 通常時に撮影した際の画像であり、血管の炎症等を見分けやすい画像

染色： ポリープに対して染色液を散布した状態で撮影した画像であり、病変の凹凸が強調された画像


NBI： 血液中のヘモグロビンが吸収しやすい光を照射した状態で撮影した画像であり、病変の近くに集まりやすい血管やそのパターンなどが強調された画像



(a) 白色光源



(b) 染色



(c) NBI

Figure 7. 内視鏡画像

そこで、提案手法ではポリープの良性・悪性のラベル付けを行うとともに、上記の内視鏡画像の種類でもラベル付けを行い、合計 6 種類のラベル付けを行う。

3.2. CNN による特徴抽出

内視鏡画像からポリープの良性・悪性の判断を行うためには、ポリープに関する画像特徴量が必要となる。しかし、SIFT などの経験的な特徴量では良性・悪性の判断が困難である。そこで、ポリープの特徴抽出を行う手法として CNN を利用する。特徴抽出に用いる CNN のモデルは AlexNet を用い、白色光源・染色・NBI の三種類の内視鏡画像を入力として、fc7 層から各内視鏡画像からポリープの特徴を抽出する。

3.3. 複数の識別器の構築

- 3.4. 抽出した特徴量から、識別器の構築を行う。識別機の構築には、白色光源・染色・NBIの三種類の各特徴量を持いる。ポリープによって良性・悪性の判断がしやすい特徴量が異なる。そこで、図8に示すように三種類の特徴量からなる組み合わせ数分識別機を構築することで、ポリープによって判断がしやすい画像の種類に対応した識別を行う。また、各識別器の入力は識別器構築時に用いた特徴量の種類と対応する種類の画像とし、出力は入力した各画像の種類でそれぞれ良性・悪性を判定した結果とする。




Figure 8. 複数の識別器

3.5. 投票処理による分類結果の統合

構築した各識別器の結果は、同じポリープであっても識別器によって違う判定がされている場合がある。そこで、各識別器で出力された判定結果から投票処理を行うことで結果を統合し、最終的な判定結果を算出する。投票処理では、各識別器で得られた判定結果の分類スコアを重みとして評価値に投票する。

投票処理の計算式を式(9), (10), (11)に示す。ここで、Score は SVM で判定された結果の分類スコア、 n は識別数、vote は SVM の判定結果、Benign は良性ポリープである確立、Malignant は悪性ポリープである確立を示す。

$$Label = Judge(vote) \quad (9)$$

$$vote = \sum_{n=1}^{12} Score_n \quad (10)$$

$$Judge = \begin{cases} Benign & (if \ vote < 0) \\ Malignant & (otherwise) \end{cases} \quad (11)$$

以上のようにして, 7 種類の識別器から判定された結果から分類スコアを用いた投票処理を行い, ポリープによって良性・悪性の判定の難易度が画像ごとに違うことに対応することで, それぞれの識別器での判定結果よりも高精度な分類を図る.

3.6. 評価実験

提案手法の有効性を確認するために精度評価を行った. データセットは白色光源・染色時・NBI を各 360 枚, 各種類の画像での良性・悪性の内訳は各 180 枚とし, 評価方法は Leave One Out 法により行った. 精度評価を表 4 に示す. ここで, Sensitivity は悪性の正答率, Specificity は良性の正答率, Accuracy は全体の正答率, PPV は悪性の的中率, NPV は良性の的中率を示している.

Table4. 精度評価[%]

	<i>Sensitivity</i>	<i>Specificity</i>	<i>Accuracy</i>	<i>PPV</i>	<i>NPV</i>
白色光源	75.6	80.9	78.0	82.7	73.3
染色時	87.8	66.0	72.5	52.2	92.7
NBI	72.8	56.6	60.2	32.7	87.7
白色+染色	84.4	75.7	79.4	72.2	86.6
白色+NBI	56.5	52.2	53.3	28.8	77.7
染色+NBI	81.3	72.3	76.1	67.7	84.4
白色+染色+NBI	81.3	71.1	75.2	65.5	85.0
投票結果	90.4	85.4	87.7	84.4	91.1

表 4 より, 提案手法は Sensitivity や PPV が各識別器よりも高いことが確認できる. ポリープ分類において, 悪性ポリープの誤分類をしてはならないため, Sensitivity や PPV の高い提案手法は, ポリープの分類に対して有効である. また, 全体の正答率を示す Accuracy についても各識別器よりも高いことが確認でき, 提案手法の有効性を確認できる.

4. 血管情報を用いた大きさ・形状復元手法

提案手法では, 内視鏡画像の陰影情報をもとに光学的制約式を用いてポリープの大きさ形状復元を行うため, 光学的制約式を利用時の内視鏡カメラから物体までの奥行き Z , 物体表面の反射係数 C 等の初期パラメータが必要となる. そのため, 血管の太さを参照物体とし, 撮影する二枚の内視鏡画像においてフレーム間での血管の太さの違いから内視鏡カメラの移動量 ΔZ を幾何学的に計算し, 二枚の内視鏡画像における対応関係をもとにパラメータの算出を行う.

はじめに, 二枚の内視鏡画像それぞれで血管領域の抽出を行い, 血管の集合領域での内視鏡画像間における対応領域抽出する. そして, 対応関係が得られる血管の集合領域において血管の対応領域を抽出し, 二枚の内視鏡画像における対応関係をもとにパラメータの算出を行い, ポリープの大きさ・形状復元を行う. 処理手順を以下に示す.

Step.0 血管領域抽出

Step.1 二枚の内視鏡画像間における対応領域抽出

Step.2 血管の対応領域抽出

Step.3 ポリープの大きさ・形状復元

4.1. 血管領域抽出

血管領域抽出は、眼球の血管領域抽出を目的とする Frangi Filter¹⁵⁾を腸の血管領域抽出に応用した手法¹⁶⁾を利用して抽出を行う。血管領域の抽出結果を図 9, 10 に示す。



(a) 内視鏡画像

(b) 血管エッジ検出後


Figure 9. 血管領域抽出

ここで、検出した血管領域全体で構造解析および移動先検出を行う場合、計算量が膨大となるため、血管の集合領域毎に二枚の内視鏡画像間における対応領域抽出を行う。

4.2. 二枚の内視鏡画像間における対応領域抽出

血管の集合領域の二枚の内視鏡画像間における対応領域抽出は、血管のエッジ情報を用いて行う。対応領域抽出は、初めに血管のエッジを判定し、血管の集合領域毎にラベル付けを行う。

ここで内視鏡画像から得られるエッジは、血管以外に腸内壁やポリープのエッジ情報があるため、各エッジにおける近傍の輝度情報から血管のエッジを判定する。エッジにおける近傍の輝度情報は、図 10(a)に示すように血管の場合では、エッジ近傍の領域において同様の輝度情報を持つ。図 10(b), 図 10(c)に示す血管以外の場合では、エッジを境界として近傍の輝度情報は異なる輝度情報を持つ傾向がある。



(a) 血管

(b) ポリープ

(c) 肉壁

Figure 10. 各エッジにおける近傍の輝度情報

エッジ近傍の輝度情報を用いて抽出した非血管エッジの例を図 11 に示す.




Figure 11. 提案手法で得られた肉壁エッジ

抽出した血管の集合領域毎にラベリングを行い, 二枚の内視鏡画像間で対応関係が得られる最も面積の大きな領域を対応領域(以下, CE_1, CE_2 として抽出する. CE_1, CE_2 の重心をそれぞれ求めることで, 画像間の移動方向・距離を求める. 検出した CE_1, CE_2 の例を図 12(a), 図 12(b), 二枚の画像間での重心移動を図 12(c)に示す.




Figure 12. 二枚の内視鏡画像の対応領域

求めた重心の移動方向・距離を一枚目の重心の座標に適用し, 二枚目における移動先の血管領域を推定する. 移動先の重心推定結果を図 13(a), 移動先の血管領域を図 13(b)に示す.




Figure 13. 提案手法による推定結果

4.3. 血管の対応領域抽出

得られた対応領域抽出において血管構造解析を行い、一枚目、二枚目それぞれで血管構造情報をグラフ化し、類似度の最も高い領域を血管の対応領域として抽出する。以下に処理手順を示す。

- Step.1 血管に対して細線化処理を適用し、反時計回りに輪郭点追跡を行い、輪郭点座標を取得する。
- Step.2 輪郭点座標を参照し、輪郭点上の血管の構造について端点を1，連結点を2，分岐点を3の三つのパターンに分類し、ラベル付けを行う。
- Step.3 ラベル付けを行った構造情報を用いて横軸を輪郭点数，縦軸をラベル付けによる値としてグラフ化する。
- Step.4 一枚目のグラフの開始点，終了点を1点ずつスライドさせながら二枚目グラフとの類似度が最大となる領域を探索し，対応する血管領域として検出する。

4.4. 三次元形状復元の手順

対応する血管領域検出終了後，文献¹¹⁾の処理と同様に二枚間のカメラの移動量 ΔZ ならびに反射係数 C を推定し，カメラの移動量 ΔZ ならびに反射係数 C を用いて，文献¹³⁾の三次元形状復元手法を用いて，ポリープの三次元形状復元を行う。以下に処理手順を示す。

- Step.1 対応する血管領域の検出後，SIFTにより対応点からカメラ移動量 ΔZ を推定する。
- Step.2 ΔZ を用いて先行研究と同様に復元初期点の反射係数 C を推定する。
- Step.3 文献¹³⁾の前準備として文献¹⁴⁾を用いて一枚目の内視鏡画像のLambert化を行う。
- Step.4 Step.3までに取得した値を用いて文献¹³⁾によるポリープの三次元形状復元を行う。


4.5. 評価実験

提案した手法の有効性を確認する目的で，実際の内視鏡画像を用いて実験を行った。まず二枚の内視鏡画像から対応する血管領域の検出を行い，文献¹¹⁾との検出精度評価比較を行う。次に，得られた二枚


の対応する血管領域を用いてパラメータ算出を行い, 得られたパラメータを用いて三次元形状復元を行う. なお, 本実験では画像の解像度が 1024×1024 pixel のものを使用した.

4.5.1. 対応する血管領域の検出

血管領域検出を行う内視鏡画像 1 を図 14(a), 14(b)に内視鏡画像 2 を 15(a), 15(b)示す. ここで, 内視鏡画像 1 における画像間のフレーム差は 5 フレームであり, 内視鏡画像 2 における画像間のフレーム差は 8 フレームである.




(a) 一枚目の画像




(b) 二枚目の画像(5 フレーム後)

Figure 14. 内視鏡画像 1



(a) 一枚目の画像



(b) 二枚目の画像(8 フレーム後)

Figure 15. 内視鏡画像 2

文献¹¹⁾による検出結果を図 16, 18 に提案手法による検出結果を図 17, 19 に示す.




Figure 16. 内視鏡画像 1 の検出結果(文献¹¹⁾)

Figure 17. 内視鏡画像 1 の検出結果(提案手法)




Figure 18. 内視鏡画像 2 の検出結果(文献¹¹⁾)

Figure 19. 内視鏡画像 2 の検出結果(提案手法)

図 16,17 の結果から、従来手法と提案手法で異なる血管領域を検出しているが、それぞれ対応した血管の対応領域を検出できていることが確認できる。図 18,19 の結果を見ると、従来手法では血管の対応領域を正確に検出できていないのに対し、提案手法では対応した血管領域を適切に検出できている。

4.6. 血管対応領域抽出精度

一枚目の画像で追跡対象となった血管領域に対応する二枚目の血管領域と二枚目の検出結果と比較し、対応する血管領域が検出できていると判断した場合に検出可能、検出できていないと判断した場合に検出不可能とし 20 組の内視鏡画像ペアを用いて精度評価を行った。

表 5 から、提案手法でより汎用的に血管の対応領域を抽出出来ていることが確認できる。

Table5. 血管対応領域抽出精度


	検出可能	検出不可能	検出成功率(%)
文献 ¹¹⁾	11	9	55
提案手法	16	4	80

4.7. 三次元形状復元


図 14 に対して, 提案手法によって得られたパラメータを用いて三次元形状復元を行った. 得られたパラメータを表 6 に, 三次元形状復元結果を図 20 に示す.

Table6. パラメータ推定結果


パラメータ	文献 ¹¹⁾	提案手法
ΔZ	3.7021	3.7019
C	74.3	76.1
復元対象の高さ(mm)	6.19	6.21



(a) ポリープ



(b) 復元結果(文献¹¹⁾)



(c) 復元結果(提案手法)

Figure 20. 内視鏡画像 1 の形状復元結果

図 20 から, 提案手法ならびに従来手法でパラメータが推定できた場合の同等の形状復元結果が得られていることを確認することができる. 血管対応領域抽出精度評価の結果から提案手法では, 従来手法と比較してより汎用的に血管の対応領域を抽出できており, これらの結果から, より多様な内視鏡環境でのポリープの三次元形状復元を可能としている.

5. おわりに

本研究では, 医療診断支援を目的として, 内視鏡画像からポリープ検出を行う検出手法, 検出したポリープに対して良性・悪性の分類を行う分類手法, さらには分類の困難なポリープに対して, 大きさ・形状復元を行う形状復元手法を提案した. ポリープの検出では, 一般物体認識を目的として学習を行なった CNN を利用し, 内視鏡画像を用いて Fine-Tuning を行うことで, 十分な学習データを用意できない内視鏡画像において, CNN による高精度なポリープ検出を提案した. ポリープの良性・悪性分類では, 白色光源・染色・NBI の三種類の画像から得られる特徴量を利用し, 高精度な良性・悪性分類手法を提案した. ポリープの形状復元では, 血管の構造解析を利用することで, 画像の変化や回転に対応した頑健な血管対応領域抽出手法を提案し, より多様な内視鏡環境でのポリープ形状復元を実現した. 今後, ポリープの三次元形状復元結果を良性・悪性分類に応用するなど, さらなる内視鏡医療診断支援を目的とした研究開発を進める.

謝辞

本研究は中部大学総合工学研究所 平成 29 年度の第 7 部門の援助および科研費基金基盤研究(C)(#17K00252)を受け遂行されたものであり、ここに謝意を表します。

参考文献

- 1) D. K. Iakovidis, D. E. Maroulis, S. A. Karkanis, and A. Brokos, "A comparative study of texture features for the discrimination of gastric polyps in endoscopic video," Computer-Based Medical Systems, 2005. Proceedings. 18th IEEE Symposium on IEEE, pp.575-580 (2005).
- 2) S. Karkanis, D. K. Iakovidis, D. E. Maroulis, D. Karras, M. Tzivras, *et al.*, "Computer-aided tumor detection in endoscopic video using color wavelet features," Information Technology in Biomedicine, IEEE Transactions on, vol.7,no.3,pp.141-152,(2003).
- 3) L. Alexandre, N. Nobre, J. Casteleiro, *et al.*, "Color and position versus texture features for endoscopic polyp detection," BioMedical Engineering and Informatics, 2008.BMEI 2008. International Conference on, vol.2IEEE,pp.38-42 (2008).
- 4) Y. Iwahori, T. Shinohara, A. Hattori, R. J. Woodham, S. Fukui, M. K. Bhuyan, and K. Kasugai, "Automatic polyp detection in endoscope images using a hessian lter," Proceedings of MVA, pp.21-24, (2013).
- 5) J. Bernal, F.J. Sanchez, G. Fernandez-Esparrach, D. Gil, C. Rodriguez, and F. Vilari~no, "WM-DOVA maps for accurate polyp highlighting in colonoscopy: Validation vs. saliency maps from physicians," Computerized Medical Imaging and Graphics, vol.43, pp.99-111, (2015).
- 6) Y. Iwahori, H. Hagi, Y. Usami, R. J. Woodham, A. Wang, M. K. Bhuyan, K. Kasugai, "Automatic Polyp Detection from Endoscope Image Using Likelihood Map Based on Edge Information", ICPRAM 2017, pp.402-409, (2017).
- 7) Y. Lecun, L. Bottou, Y. Bengio, P. Haffner, "Gradient-Based Learning Applied to Document Recognition", Proceedings of the IEEE, Vol.86, No.11, pp.2278-2324, (1998).
- 8) Y. Mori *et al.*, "Novel computer-aided diagnostic system for colorectal lesions by using endocytoscopy (with videos)." Gastrointestinal endoscopy Vol.81, no.3, pp.621-629, (2015).
- 9) B. K. P. Horn, "Obtaining shape from shading information", MIT Press, pp.123-171, (1989).
- 10) Y. Iwahori, D. Yamaguchi, T. Nakamura, K. Kunio, "Estimating Reflectance Parameter of polyp Using Medical Suture Information in Endoscope Image", Proceeding of ICPRAM 2016, pp.503-509, (2016).
- 11) Y. Iwahori, T. Suda, K. Funahashi, H. Usami, A. Wang, M. K. Bhuyan, K. Kasugai, "Shape Recovery of Polyp from Endoscope Image Using Blood Vessel Information", Springer Studies in Computational Intelligence 726, pp.165-184, Selected Paper among CSII 2017, (2017).
- 12) T. Nima, *et al.* "Convolutional neural networks for medical image analysis: Full training or ne tuning?." IEEE Transactions on Medical Imaging, Vol.35. No.5, pp.1299-1312, (2016).
- 13) H. Usami, Y. Iwahori, Y. Hanai, B. Kijsirikul, K. Kasugai, "Recovering Shape from Endoscope Image Using Two Light Sources", International Journal of Software Innovation (IJSI), Volume 5, Issue 2, pp. 33-54, DOI:10.4018/IJSI.2017040103, April-June (2017).
- 14) N. Ikeda, H. Usami, Y. Iwahori, B. Kijsirikul, K. Kasugai, "Generating Lambertian Image by Removing Specular Reflection Component and Difference of Reflectance Factor Using HSV", Proc. of ITC-CSCC 2016, T2-5, Computer Vision (2), pp.547-550, (2016).

- 15) A. F. Frangi, *et al.*, "Multiscale vessel enhancement filtering." International Conference on Medical Image Computing and Computer-Assisted Intervention", Springer Berlin Heidelberg, (1998).
- 16) M. Golhar, Y. Iwahori, K. Funahashi, M. K. Bhuyan, K. Kasugai, "A Robust Method for Blood Vessel Extraction in Endoscopic Images with SVM-based Scene Classification", ICPRAM 2017, pp.148-156, (2017).
- 17) S. Hui-Liang and Q. Y. Cai. "Simple and efficient method for specular removal in an image." Applied Optics, Vol.48, No.14, pp.2711-2719, (2009).
- 18) D. Arthur and S. Vassilvitskii, "k-means++: The advantages of careful seeding, "Proceedings of the eighteenth annual ACM-SLAM symposium on Discrete algorithms Society for Industrial and Applied Mathematics, pp. 1027-1035 (2007).
- 19) K. Simonyan, and A. Zisserman. "Very deep convolutional networks for large-scale image recognition." arXiv preprint arXiv:1409.1556, (2014).
- 20) J. Bernal, N. Tajkbaksh, F. J. Sanchez *et al.*, "Comparative Validation of Polyp Detection Methods in Video Colonoscopy: Results from the MICCAI 2015 Endoscopic Vision Challenge", IEEE Transactions on Medical Imaging, Vol.36, No.6, pp.1231-1249, (2017).
- 21) D. Kingma and J. Ba. "Adam: A method for stochastic optimization." arXiv preprint arXiv:1412.6980, (2014).
- 22) J. Silva, A. Histace, O. Romain, X. Dray, B. Granado, "Towards embedded detection of polyps in WCE images for early diagnosis of colorectal cancer", International Journal of Computer Assisted Radiology and Surgery, Springer Verlag (Germany), Vol.9, No.2, pp.283-293, (2014).
- 23) D. G. Lowe, "Object recognition from local scale-invariant features", The proceedings of the seventh IEEE International Conference on Computer Vision, Vol.2. pp.1150-1157, (1999).
- 24) A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in Advances in neural information processing systems, pp. 1097-1105, (2012).