

畳み込みニューラルネットワークを用いた カプセル内視鏡画像における小腸病変の位置検出

宮崎 祐太^{1,a)} 白神 康平¹ 柳川 由紀子^{1,3} 越後 富夫² 八木 康史¹

概要: この研究は、畳み込みニューラルネットワークを用いてカプセル内視鏡画像中の病変領域を検出する方法を提案する。畳み込みニューラルネットワークを用いて、病変を含んでいるか否かの2クラスで分類した大量の局所領域画像を学習する。病変は様々な形をとるため、病変領域の検出には大量の局所領域が効果的にはたらく。従って本提案手法では、学習した検出器の出力結果を投票することで病変らしさを表す投票画像を作成する。得られた投票画像中で投票値が大きい領域を病変領域とする。実験の結果、本提案手法の有効性を確認した。

キーワード: カプセル内視鏡, 小腸病変, 深層学習, 畳み込みニューラルネットワーク

1. はじめに

カプセル内視鏡は、消化管内部を撮影する用途で用いられるカプセル型の小型内視鏡である [1]。カプセル内視鏡はサイズが小さく、水を飲むだけで検査ができるため患者への負担が少ない。しかし一方で、医師への負担が大きいという問題がある。カプセル内視鏡映像は毎秒数枚程度の低フレームレートで解像度も高くなく、小腸の蠕動運動によって激しく動く。医師はその映像を数時間を見続け、目視で病変の有無を判別しなければならない。医師にとって大きな負担となる作業であり、病変の見逃しにつながる危険性がある。そこで、カプセル内視鏡映像の解析を計算機で補助することが考えられる。補助の内容は、病変が写っている画像の検出や、画像中の病変の位置の特定、写っている病変の種類分類、映像中の病変のトラッキングなど様々なことが考えられる。本研究ではその内、カプセル内視鏡映像中で病変が写っている画像を検出することと、画像中での病変の大まかな位置を見つけることを目的とする。本提案手法ではカプセル内視鏡画像の各画素に対して病変らしさを求め、これを基に病変画像の検出を行っているためである。

関連研究は多々あるが、高い精度が報告されている病変

の種類は限られており、従来手法では対処が難しい種類の病変が存在する。そこで本研究では検出が難しい種類の病変を検出するために近年広く用いられるようになった深層学習に着目する。深層学習の中でも畳み込みニューラルネットワークは、2012年のImageNet Large Scale Visual Recognition Challenge (ILSVRC2012)の1000クラス一般物体認識部門で優勝した AlexNet[2] を皮切りに、画像処理の分野で注目を集めている。従来の機械学習では何らかの特徴量を入力として多クラス分類や回帰などを行う分類器を学習するのに対し、深層学習ではどのような特徴量を使うかということすらも学習できることが最大の違いである。本研究では、小腸の病変の特徴抽出を畳み込みニューラルネットワークに任せることで、人間が設計した特徴量を使用した従来研究を超える性能を達成することを目指す。

本論文では、2章でカプセル内視鏡から得られる小腸画像や病変の種類、関連研究について紹介し、3章で畳み込みニューラルネットワークを用いた病変位置検出方法について説明する。4章で、提案手法を評価するための実験を行った結果と考察を示し、最後に5章で結論と今後の課題を述べる。

2. 小腸病変と関連研究

カプセル内視鏡映像には、小腸病変の他に健常な腸壁や腸壁のしわ等が写る。小腸病変には、リンパ管拡張症や潰瘍のような白みを帯びた病変や、エリテマトーデスや血管拡張症のように赤みを帯びた病変などのさまざまな種類が存在する (図 1)。先行研究である井村らの研究 [3] から、

¹ 大阪大学
Osaka University

² 大阪電気通信大学
Osaka Electro-Communication University

³ オムロン株式会社
OMRON Corporation

a) miyazaki@am.sanken.osaka-u.ac.jp

各病変の出現割合を図2に示す。上位5種類の病変で全体の75%を占めていることが分かる。図2の病変の内、大量出血や潰瘍に対する研究は数多く存在する[4], [5], [6]。その反面、これら以外の病変に対する研究は精度が高くない。例えば、赤みを帯びた病変である血管拡張症と、白みを帯びた病変であるリンパ管拡張症を対象とした井村らの研究[3]があげられる。大量出血はカプセル内視鏡画像の半分を覆うように鮮やかな赤色の血が写り、潰瘍の多くは白っぽい色味をしている。どちらも健常な腸壁とは大きく異なる色味でサイズも比較的大きく、既存手法で高い精度を達成できている。しかし血管拡張症とリンパ管拡張症の内、特に血管拡張症は色味が薄いものや細長い形状のものが存在し、既存手法では健常な腸壁との区別がつかない場合が多く見られた。本論文では[3]と同じく血管拡張症とリンパ管拡張症を対象とし、畳み込みニューラルネットワークを用いて病変検出器の学習を行って精度の向上を目指す。

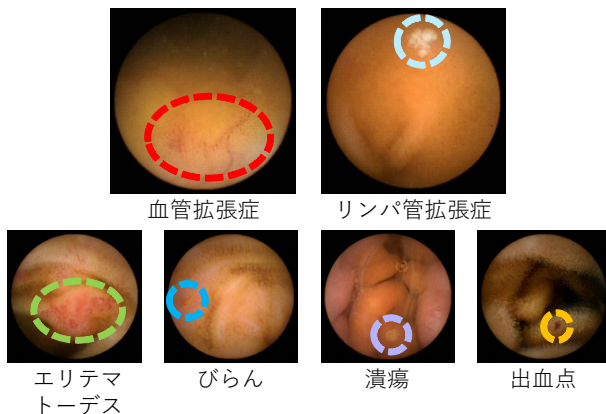


図1 各小腸病変例(点線内部が医師によって病変と診断された領域)




図2 各症状の出現割合

3. 畳み込みニューラルネットワークを用いた病変画像と位置の検出手法

本提案手法の流れを図3に示す。医師がカプセル内視鏡画像中の病変を目視で見つけられていることから、病変部分とその周辺の領域には何らかの違いが存在する。本提案

手法ではこの違いを扱うために、カプセル内視鏡画像を分割して局所領域画像を作成する。そして局所領域画像ごとに病変か非病変か判定する2クラス分類器を畳み込みニューラルネットワークを用いて学習する。テスト時では学習時と同様に局所領域画像を作成し、学習済みの局所病変領域検出器に入力して検出結果を得る。最後に、局所領域画像ごとに得られた検出結果を用いて元画像の各画素に対して病変らしさを求め、それを基に病変の有無と病変位置を推定する。本章では、3.1節で深層学習と畳み込みニューラルネットワークの紹介をした後、3.2節で局所領域画像の作成方法を示し、3.3節で局所病変領域検出ネットワークの詳細について述べ、3.4節で病変位置検出や病変画像検出の手法について詳しく説明する。

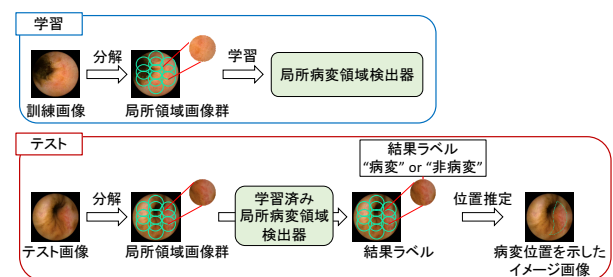


図3 本提案手法の流れ

3.1 畳み込みニューラルネットワークとは

畳み込みニューラルネットワークは、2012年のImageNet Large Scale Visual Recognition Challenge (ILSVRC2012)[7]でのAlexNet[2]の登場以来、コンピュータビジョンの分野において広く用いられるようになった。ILSVRCは巨大なデータベースでの一般物体認識のコンテストである。従来手法では、Scale-Invariant Feature Transform (SIFT)[8]に代表される人間が設計した特徴量や、フィッシャーベクトル[9]のような統計解析法を組み合わせていたのに対し、畳み込みニューラルネットワークでは用いる特徴量すらも学習することができる。畳み込みニューラルネットワークを用いた手法は従来手法よりも圧倒的に良い性能を示し、畳み込みニューラルネットワークの高いポテンシャルを広く知らしめることになった。

畳み込みニューラルネットワークは、Fukushimaらのネオコグニトロン[10]を起源としており、生物の視覚野の仕組みからヒントを得て設計されている。視覚野に存在する神経細胞の内、網膜上の特定のパターンの位置に対して厳密に反応する単純型細胞を畳み込み層、微小なずれが生じていても反応する複雑型細胞をプーリング層で表現している[11], [12], [13]。畳み込み層では、入力される画像に対して画像処理におけるフィルタリングにあたる処理を畳み込みとして行う。プーリング層は通常畳み込み層の出力を入力とし、入力画像中の小領域を移動させながらその中の平

均値や最大値などを出力する。これらの畳み込み層やプーリング層、さらに典型的な多層ニューラルネットも組み合わせて畳み込みニューラルネットワークは構成され、一般的にその学習には確率的勾配降下法 [14] が用いられる。確率的勾配降下法の対象となる誤差関数は、教師データとの差異を表すように設計され、特に ILSVRC の問題のような多クラス分類問題では交差エントロピーがよく用いられる。この誤差関数の勾配計算では誤差逆伝播法 [15] を用いる。

3.2 局所領域画像の生成

同じ種類の病変でも、図 4 のように多種多様の形状が存在する。図 4(c), (d) は病変境界が明瞭でない画像で、真値領域は画素単位で判別するのではなく、近傍画素に病変が存在する場合も病変と定義する。病変を形状から判定するのは困難であることから、本研究では病変領域と健常領域の色やテクスチャの違いから病変の有無を判別する。そのために、カプセル内視鏡画像を小さく分解した局所領域画像に着目する。この局所領域画像ごとに病変の判別結果を求め、これらを統合することで病変画像と病変位置を検出する。

本研究で用いたカプセル内視鏡から得られる 256×256 の小腸画像に対し、直径 99 ピクセルのウィンドウをラスタスキャンして円形の局所領域画像を得る。病変局所領域画像作成においては、病変領域が局所領域画像にもれなく写るように、図 5 のように縦横で 5 ピクセルずつ進ませる。そのときに黒いフレーム部分が写りこむ局所領域画像は除外する。

局所領域画像に分解した後、病変か非病変かのラベル付けをする。病変の定義には、図 4 のような病変の真値領域画像を用いる。局所領域画像の直径 99 ピクセルの円の中に、面積の 0.1% 分の真値領域が入っていれば局所病変領域として定義する。 $(\frac{99}{2})^2 \pi \times 0.001 \approx 7.69$ より、8 ピクセル以上の真値領域が存在すれば局所病変領域として定義している。




図 4 病変が写っているカプセル内視鏡画像 (上段) と病変の真値領域画像 (下段)




図 5 局所領域画像のサイズと作り方

3.3 局所病変領域検出ネットワーク

入力される局所領域画像中の局所病変領域を検出するために、図 6 で示す局所病変領域検出ネットワークを用いる。図 6 中の conv, pool は、それぞれ畳み込み層とプーリング層を表す。各層の設定を表 1 に示す。カーネル数とカーネルサイズは、畳み込み層のフィルタやプーリング層の小領域の数と大きさを表す。ストライドは、カーネルをその大きさの画素ずつずらして処理を行うことを意味する。活性化関数は生物の神経細胞の性質をモデル化したもので、畳み込み層の出力に対して適用する。本ネットワークでは、正規化線形関数 (Rectified Linear Unit : ReLU)[16] を用いている。プーリング層では、カーネル領域中の最大値をとる最大プーリングを用いる。norm 層は入力画像全体のコントラストと明るさを調節するための層で、本ネットワークでは Local response normalization (LRN)[17] を用いる。fc は全結合層を表し、1 層目の fc1 のユニット数は 1024、2 層目の fc2 は 2 とする。また fc1 では、学習時に確率的にユニットを無効化して過学習を緩和させることができるドロップアウト [18] を適用しており、その確率を表すパラメータは 0.5 とする。

M 枚の局所領域画像 $\{I_1, \dots, I_M\}$ とその正解ラベル $\{d_1, \dots, d_M\}, d_m \in \{0, 1\}$ (1: 局所病変領域, 0: 局所非病変領域) から成る学習データ集合を $\{(I_1, d_1), \dots, (I_M, d_M)\}$ とおくと、局所病変領域検出ネットワークの誤差関数 $L(w)$ は式 (1) の交差エントロピーとして定式化できる。ただしここで、 w はネットワークのすべてのパラメータを並べたベクトルを表し、 v は fc2 層の出力で v_0 は局所非病変領域、 v_1 は局所病変領域を表す。局所病変領域検出ネットワークのパラメータ w の学習は、順伝搬により求め、誤差逆伝播法 [15] によりパラメータ w の勾配を計算し、勾配降下法により w を更新することで実現する。

$$L(w) = - \sum_{m=1}^M \{ (1 - d_m) \log v(I_m; w)_0 + d_m \log v(I_m; w)_1 \} \quad (1)$$

誤差関数 $L(w)$ を最小化させることで局所病変領域検出器の学習を行う。最小化は確率的勾配法 [14] を用いて行い、

この勾配計算には誤差逆伝播法 [15] を用いる。

3.4 病変画像検出と病変位置検出

病変位置検出は、局所病変領域検出の結果を統合することで行う。図 7 右のように元画像と同じサイズの投票画像を用意し、局所病変領域に対し元画像での座標を算出、投票画像の同じ座標の画素値に投票をする。各画素に対する 1 回の投票値は、その画素を含んでいる局所領域画像の数の逆数としている。これは 1 回の投票値を 1 として全ての局所領域画像に対して投票をした場合、図 8 のように投票画像の最大画素値が不均一となるためである。この方法では、端の画素は局所領域画像に含まれる回数が少ないので、1 回の投票値が高くなり投票値が不安定になりやすい。そのため、投票回数が 40 以上となる領域を病変検出領域とし、端部分は除外する。本手法における病変検出対象領域を図 9 に示す。病変検出対象領域の投票回数を定めるにあたって、カプセル内視鏡画像の中央部分を重視するため、直径 99 ピクセルの局所領域画像が病変定義の 8 ピクセルだけ重なり合うように 2 つ並べた直径 190 ピクセルの円形を想定した。投票回数を 40 以上としているのは、この円形中の最小の投票値が 40 であったからである。

こうして得た投票画像に対し、1 ピクセルでも閾値 θ より大きい投票値をもつ画像を病変画像とする。そして、同じ閾値 θ より大きい領域を推定病変位置とみなす。1 回の投票値は各画素を含む局所領域画像数の逆数のため、投票画像全体の最大値は 1 である。したがって、閾値の範囲は $0 \leq \theta < 1$ となる。

4. 病変画像検出と病変位置検出の性能評価実験

提案手法の有効性を確認するために、実際のカプセル内視鏡画像を用いて実験を行った。本実験では、血管拡張症とリンパ管拡張症に対しそれぞれ別々に学習を行い、得られた検出器の性能と、病変画像の検出精度、推定した病変の位置の精度の評価をした。本章では、実験のデータセットと学習の設定を 4.1 節で説明し、4.2 節で実験結果を評価する指標について述べる。そして、4.3 節で検出器の学習曲線や性能について述べ、4.4 節で病変画像検出と病変位置検出の精度を評価する。

4.1 実験設定

畳み込みニューラルネットの学習には、データセットと学習の設定が重要となる。本節では、4.1.1 節で用いたデータセットとデータ拡張の方法について述べ、4.1.2 で学習の初期設定について示す。

4.1.1 データセット

本研究では、大阪市立大学附属病院の医師の協力の下、カプセル内視鏡の検診を受けた 300 人の患者の診察結果か

ら得たデータを用いる。このデータは、井村ら [3] が用いたものと同一である。このデータの内、血管拡張症の画像 100 枚とリンパ管拡張症の画像 96 枚、健常な小腸の画像 100 枚を用いる。学習データとしては血管拡張症とリンパ管拡張症の画像を用いる。それぞれ別々に学習を行い、2 つの検出器を作成する。学習データは偏りを緩和させるために被験者ごとの交差検証を行う。血管拡張症が確認された被験者は 30 人、リンパ管拡張症が確認された被験者は 33 人であったため、それぞれ 30 分割交差検証、33 分割交差検証を行う。病変画像の誤検出度合いを確認するために、テストデータには学習に用いない病変画像に加え、健常な小腸の画像を使用する。

一般的に深層学習では大量のデータが必要となるため [2]、カプセル内視鏡から得られる元画像を回転・反転してデータ拡張を行った。今回使用したカプセル内視鏡から得られる画像は 256×256 ピクセルのサイズで、円形の中心部に小腸の内部が映っている。そのため、元画像に回転・反転を加えても同じ形式を保ちながら学習データを増やすことができる。本研究では元画像を 10 度ずつ回転・反転することで、1 枚の元画像につき 72 枚の回転・反転した画像を得る。拡張した元画像を 3.2 節で述べた方法で局所領域画像に分解して、各テストセットの学習データは約 400 万枚、テストデータは 7000 枚～15000 枚となった。各テストセットでデータ総数が変わっているのは、被験者ごとの小腸画像の枚数が不揃いだからである。

元画像全体を覆うような大きな病変は今回用いたデータには存在しないため、必然的に分解した局所領域画像の数は病変と定義する方が少なくなる。病変と非病変の画像数が著しく異なると学習の際に偏りが生じるため、学習データの非病変の局所領域画像をランダムサンプリングをして病変と非病変の画像数の差が 10 万枚程度になるようにした。また、テスト用の画像は回転・反転させたものから得られる局所領域画像は使用せず、オリジナルの画像から得られる局所領域画像のみを使用した。

4.1.2 学習の設定

畳み込みニューラルネットワークを用いた学習では様々なハイパーパラメータが用いられる。本実験では学習係数の初期値を 0.01 とし、15000 イテレーションごとに $\frac{1}{10}$ 倍にする。学習は 60000 イテレーション回している。また、多くの入力画像を並列計算をして学習時間の短縮を行うミニバッチ学習を用いており、その際のミニバッチ数は 1000 とした。さらに学習の収束性能を良くするためにモメンタム項 [15] を用い、モメンタム係数を 0.9 とした。

4.2 評価に用いる指標

実験結果の評価は、局所病変（非病変）領域検出率（式 (2)、式 (3)）と病変（非病変）画像検出率（式 (4)、式 (5)）、病変位置画検出率（式 (6)）を用いて行う。本研究では病変




図 6 ネットワークの構成

表 1 ネットワークの各層の設定

層名	カーネル数	カーネルサイズ	ストライド	活性化関数	プーリング
conv1	12	7×7	2	ReLU	
pool1		3×3	2		最大プーリング
conv2	49	5×5	2	ReLU	
pool2		2×2	2		最大プーリング
conv3	72	3×3	2	ReLU	
pool3		2×2	2		最大プーリング

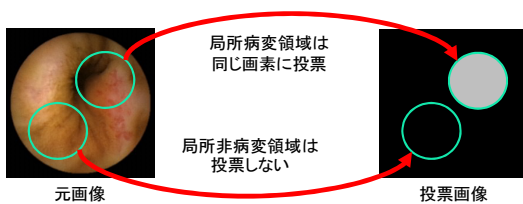


図 7 投票の概要図

$$\text{局所病変領域検出率} = \frac{\text{検出できた局所病変領域数}}{\text{総局所病変領域数}} \quad (2)$$

$$\text{局所非病変領域検出率} = \frac{\text{検出できた局所非病変領域数}}{\text{総局所非病変領域数}} \quad (3)$$

$$\text{病変画像検出率} = \frac{\text{検出できた病変画像数}}{\text{総病変画像数}} \quad (4)$$

$$\text{非病変画像検出率} = \frac{\text{検出できた非病変画像数}}{\text{総非病変画像数}} \quad (5)$$

$$\text{病変位置検出率} = \frac{\text{病変位置を推定できた画像数}}{\text{総病変画像数}} \quad (6)$$




図 8 すべての局所領域画像が投票された投票画像と局所領域画像のイメージ画像




図 9 病変検出対象領域 (左図: 元画像, 右図: 投票画像)

の大きな位置を求めることを目的としているため、推定した病変位置の内、真値領域の 90% が含まれる病変画像を病変位置を推定できた画像とし、この割合を病変位置検出率として定義する。ただし、3.4 節で述べた病変検出対象領域内の画素のみ勘定に入れる。

4.3 局所病変領域検出の結果の評価と考察

局所病変領域検出器の学習曲線の例を図 10, 図 11 に示す。血管拡張症とリンパ管拡張症にかかわらず図 10 のように収束する例と図 11 のように過学習が発生する例が見られた。過学習が発生したのは、血管拡張症では 30 テストセット中 19 セットで、リンパ管拡張症では 33 テストセット中 11 セットであった。過学習の原因には、データ数が不足していることやネットワークの記述力が高すぎるものがあげられる。データ数が不足していると少ない学習データ特有の特徴を学習してしまい、またネットワークの記述力が高すぎると学習データにしか現れない特徴を過剰に学習してしまうためである。したがって、より多くのデータに対して適用することや最適なネットワークをさらに模索していくことが今後の課題となる。

血管拡張症とリンパ管拡張症の識別器の評価結果を表 2 に示す。全体的に過学習するテストセットが少なかったリンパ管拡張症の方が検出精度が良くなっていることが分かる。リンパ管拡張症の局所病変領域検出率も平均 88.4% と高くはないため、前述の過学習を抑えることが課題となる。

	局所病変領域検出率 の平均 [%]	局所非病変領域検出率 の平均 [%]
血管拡張症	67.7	85.1
リンパ管拡張症	88.4	87.2

表 2 血管拡張症とリンパ管拡張症の局所領域画像の識別結果




図 10 収束する学習曲線




図 11 過学習する学習曲線

4.4 病変画像検出と病変位置検出の結果の評価と考察

投票値の閾値 0.1 から 0.9 まで変化させたときの、血管拡張症に対する位置検出の評価結果を表 3、リンパ管拡張症に対する位置検出の評価結果を表 4 に示す。表の下端では井村らの研究 [3] の結果を載せている。井村らは今回用いたデータの一部で実験をしたため、本研究とは異なる学習データセットで実験をしている。そのため単純比較はできないが、本研究の手法は血管拡張症とリンパ管拡張症のどちらにおいても井村らの病変画像検出率と非病変画像検出率を上回った。

血管拡張症の推定病変位置の例を図 12 に、リンパ管拡張症の推定病変位置の例を図 13 に示す。左から病変が写った病変画像と病変領域を記した真値画像、それに対して本手法を適用したときの投票画像と推定病変位置の画像を表す。病変画像と真値画像、投票画像にかかる青色の円は、3.4 節で述べた病変検出対象領域を示す。推定病変位置の画像には、閾値を大きくしていったときの境界線を等高線のように示している。病変の位置を正しく推定できた結果を図 12(a), (b) と図 13(a), (b) に示す。これらの病変画像に対しては局所領域画像のほとんどが正しく検出できていた。しかし図 12(c) では、局所病変領域の誤検出が原因で病変ではない位置に投票が集まっており、閾値を大きくすると真値からずれた位置に病変が推定されてしまう。図 12(d) では、局所病変領域検出に失敗して投票が少なくなってしまう、大きい閾値では病変画像として検出すらで

きないという結果になった。リンパ管拡張症でも図 13(c), (d) のように同様の結果が得られたが、全体的に血管拡張症よりもリンパ管拡張症の方が局所病変領域検出による誤検出や不検出が少なかった。表 3 や表 4 の病変位置検出率の平均の差がこの差を表す。この差は局所病変領域検出器の精度の差に起因していると考えられ、4.3 節で述べたように、データセットの拡充やネットワークの改良などを行う必要がある。しかし裏を返せば、少ない病変画像でもこれだけの精度を示すことができたと考えられる。病変画像を増やすことができれば、さらに高い精度の病変位置検出や病変画像検出が期待される。

5. おわりに

本論文では、カプセル内視鏡映像中の病変画像の検出と、画像中の病変位置の検出手法を提案した。本手法は、局所領域画像を入力とする畳み込みニューラルネットワークベースの局所病変領域検出器を学習し、学習済みの検出器の結果を用いて投票画像を作成することで元画像の各画素に対して病変らしさを求め、病変画像と病変の位置を検出する。そして提案手法の評価のため、実際のカプセル内視鏡画像に対して実験を行った。本実験では血管拡張症とリンパ管拡張症に対して別々の検出器を学習し、検出器の性能と病変画像検出の精度、推定病変位置の精度を評価した。識別器の性能評価の結果として、血管拡張症では 67.7% の局所病変領域検出率と、85.1% の局所非病変領域検出率を得た。またリンパ管拡張症では、88.4% の局所病変領域検出率と 87.2% の局所非病変領域検出率を得た。

従来研究 [3] の病変画像検出の精度は、血管拡張症では 4.00% の病変画像検出率と 75.0% の非病変画像検出率で、リンパ管拡張症では 87.5% の病変画像検出率と 50.0% の非病変画像検出率であった。学習データの母集団が異なるため単純比較はできないものの、本研究ではこれを上回る結果を得ることができた。リンパ管拡張症では、閾値 0.9 に対して 95.8% の病変画像検出率と 79.3% の非病変画像検出率、72.9% の病変位置検出率を得た。それに対して血管拡張症は 78.0% の病変画像検出率と 71.7% の非病変画像検出率、50.0% の病変位置検出率となった。

今後の課題として検出器の精度向上があげられる。検出器の学習において過学習がみられたため、データセットの偏りがより少なくなるような方法でテストを行うことや、データセットの画像数や病変の種類を増やすこと、本研究で取り組んでいる問題に最適な病変領域検出ネットワークの構成を模索することが考えられる。

閾値 θ	病変画像検出率の 平均 [%]	非病変画像検出 率の平均 [%]	病変位置検出率 の平均 [%]
0.1	91.0	23.0	81.0
0.2	90.0	30.0	73.0
0.2	89.0	36.7	72.0
0.4	86.0	42.4	71.0
0.5	84.0	49.2	69.0
0.6	84.0	54.8	66.0
0.7	83.0	59.5	64.0
0.8	83.0	64.9	57.0
0.9	78.0	71.7	50.0

	非病変画像検出率 [%]	病変画像検出率 [%]	病変位置検出率 [%]
[3]	75.0	4.00	-

表 3 血管拡張症の病変画像検出と病変領域検出の結果




図 12 血管拡張症の予測病変位置例

閾値 θ	病変画像検出率の 平均 [%]	非病変画像検出 率の平均 [%]	病変位置検出率 の平均 [%]
0.1	100	54.7	96.9
0.2	99.0	62.4	96.9
0.3	99.0	66.3	95.8
0.4	99.0	68.4	94.8
0.5	99.0	70.4	94.8
0.6	97.9	72.5	92.7
0.7	97.9	75.2	86.5
0.8	96.9	77.3	80.2
0.9	95.8	79.3	72.9

	病変画像検出率 [%]	非病変画像検出 率 [%]	病変位置検出率 [%]
[3]	87.5	50.0	-

表 4 リンパ管拡張症の病変画像検出と病変領域検出の結果

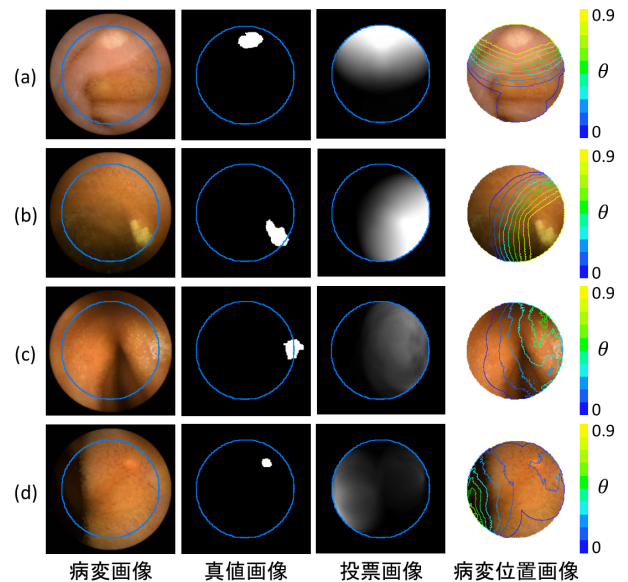


図 13 リンパ管拡張症の予測病変位置例

参考文献

- [1] Gavriel Iddan, Gavriel Meron, Arkady Glukhovskiy, and Paul Swain. Wireless capsule endoscopy. *Nature*, Vol. 405, p. 417, 2000.
- [2] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, pp. 1097–1105, 2012.
- [3] 井村祐満, 柳川由紀子, 越後富夫, 八木康史. カプセル内視鏡映像の病変局所構造における共起情報を用いた病変検出 (医用画像). 電子情報通信学会技術研究報告 = IEICE technical report : 信学技報, Vol. 114, No. 482, pp. 271–276, mar 2015.
- [4] Baopu Li and Max QH Meng. Computer-aided detection of bleeding regions for capsule endoscopy images. *Biomedical Engineering, IEEE Transactions on*, Vol. 56, No. 4, pp. 1032–1039, 2009.
- [5] Baopu Li and Max Q-H Meng. Texture analysis for ulcer detection in capsule endoscopy images. *Image and Vision computing*, Vol. 27, No. 9, pp. 1336–1342, 2009.
- [6] Piotr Szczypiński, Artur Klepaczko, Marek Pazurek, and Piotr Daniel. Texture and color based image segmentation and pathology detection in capsule endoscopy videos. *Computer methods and programs in biomedicine*, Vol. 113, No. 1, pp. 396–411, 2014.
- [7] ILSVRC, imagenet large scale visual recognition challenge. <http://www.image-net.org/challenges/LSVRC/>.
- [8] David G Lowe. Object recognition from local scale-invariant features. In *Computer vision, 1999. The proceedings of the seventh IEEE international conference on*, Vol. 2, pp. 1150–1157. Ieee, 1999.
- [9] Tommi S Jaakkola, David Haussler, et al. Exploiting generative models in discriminative classifiers. *Advances in neural information processing systems*, pp. 487–493, 1999.
- [10] Kunihiko Fukushima and Sei Miyake. Neocognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position. *Pattern recognition*, Vol. 15, No. 6, pp. 455–469, 1982.
- [11] Pietro Berkes and Laurenz Wiskott. Slow feature analysis yields a rich repertoire of complex cell properties. *Journal of Vision*, Vol. 5, No. 6, pp. 9–9, 2005.
- [12] David H Hubel and Torsten N Wiesel. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. *The Journal of physiology*, Vol. 160, No. 1, pp. 106–154, 1962.
- [13] David H Hubel and Torsten N Wiesel. Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, Vol. 195, No. 1, pp. 215–243, 1968.
- [14] Olivier Bousquet and Léon Bottou. The tradeoffs of large scale learning. In *Advances in neural information processing systems*, pp. 161–168, 2008.
- [15] David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams. Learning representations by back-propagating errors. *Cognitive modeling*, Vol. 5, No. 3, p. 1, 1988.
- [16] Vinod Nair and Geoffrey E Hinton. Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, pp. 807–814, 2010.
- [17] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, pp. 1097–1105, 2012.
- [18] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. Dropout: A simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, Vol. 15, No. 1, pp. 1929–1958, 2014.