

科学研究費助成事業 研究成果報告書

平成 28 年 6 月 15 日現在

機関番号：15401

研究種目：基盤研究(C) (一般)

研究期間：2013～2015

課題番号：25330337

研究課題名(和文)Active Learningを用いた大腸癌自動診断システム

研究課題名(英文)Automatic detection of colorectal cancer from images using active learning

研究代表者

ライチェフ ビセル(Raytchev, Bisser)

広島大学・工学(系)研究科(研究院)・助教

研究者番号：00531922

交付決定額(研究期間全体)：(直接経費) 3,800,000円

研究成果の概要(和文)：癌の自動診断システムが高い認識性能を達成するために、多種多様な病変の画像例とそのラベル(クラス情報)を含んだ大規模なデータセットは欠かせない。しかし、このようなデータセットを作成するために専門医が介入する必要があり、手間やコストがかかるため、収集が困難な場合が多い。本研究課題では、少数のラベル付き画像例から抽出された局所コンテキスト特徴量とランダムフォレストに基づいた癌の自動診断システムを開発しました。

研究成果の概要(英文)：An automatic diagnosis method for colorectal cancer from Narrow Band Imaging (NBI) has been developed, based on local context features and randomized decision forests. The local context features are based on a texton map from which texture and local context-based information is extracted from the surrounding area centered on each pixel. The features are very high-dimensional (infinite in principle) and therefore very discriminative, which combined with their huge number and the ability of random forests to handle efficiently such data without over-fitting enables us to achieve very good accuracy from a very small number of training images. Additionally, by providing local pixel-level classification the resulting method is much more general and does not depend on the concrete configuration of patterns available in the training images. The method operates locally and therefore is much better suited for video data also, which makes it applicable to more realistic diagnostic scenarios.

研究分野：情報学・機械学習

キーワード：大腸癌 癌の自動診断システム NBI画像 Active Learning Ensemble methods

1. 研究開始当初の背景

癌による死亡者数は年々増加傾向にあるが、癌の種類によって（例えば大腸癌の場合）早期発見であれば完治可能であり、死亡率を下げるため有効な手段の一つには癌検診のスクリーニング検査が考えられる。特に、近年画像診断技術の発展や性能向上により、イメージングに基づいた病状診断が一般的になりつつあるが、同時に専門医の深刻な不足で医師の診断を支援するコンピュータによる病状認識システムの研究・開発に期待が高まっている。

画像認識に基づいた癌の自動診断システムが高い認識性能を達成するために、多種多様な病変の画像例とそのラベル（クラス情報）を含んだ大規模なデータセットは欠かせない。しかし、このようなデータセットを作成するために専門医が介入する必要があり、手間やコストがかかるため、収集が困難な場合が多い。

2. 研究の目的

画像認識に基づいた癌の自動診断に必要なクラスラベル情報を持つ画像例の数を大幅に減らしても、高い認識精度が維持できるような、Active Learning とアンサンブル学習の機械学習法の開発を行う。これらの手法は、内視鏡検査によって得られた狭帯域光 Narrow Band Imaging (NBI) 画像^{[1],[2]}（拡大内視鏡画像強調イメージング）を用いて、大腸壁の血管構造から自動的に病状を推定する、という具体的な設定で開発する。しかし、開発された手法には一般性があるため、もっと広い範囲で、一般的な bio-medical イメージング関連画像から病変や他の興味ある物体を自動的に検出するにも使用できる。

3. 研究の方法

(1) 研究目的を実現するために、一つの重要な要素として、新しい active learning^[3]手法の開発が必要である。新しく開発した手法では、基本的なデータ単位として単一の物体ではなく、物体の集合あるいは配列を扱うことにより、医用画像を（あるいは一般的な画像も）画像から抽出された局所特徴の集合として自然に表現することができる。このような要素を active learning 手法に取り入れることにより、どの query 画像が（専門医によりクラス情報のラベル付けを行うための）有効な候補であるかを最適に決めることができるので、最終的には少ない学習データセットで高い認識精度を得ることが可能になる。

(2) もう一つの研究アプローチとしては、アンサンブル学習（ランダムフォレストなど）と高い識別能力を持つ局所特徴量を利用する。これによって、少数の学習画像から学習

したシステムで高い認識精度を得ることができる。Random Forest の情報統合手法としては、compound Dirichlet 分布に基づいたアルゴリズムを提案する。この手法や texton マップから抽出された local context 特徴量を用いて、バイオや医用画像の自動診断システムの開発を行う。

4. 研究成果

(1) 画像データの情報コンテンツの冗長性を利用することによって、active learning 手法が学習に必要なクラス情報でラベル付けされたデータ数を大幅に減らすことができる。これはどの画像に優先的にクラス情報を与えるか、すなわちラベル付けするには有効な候補であるかを最適に決めることによって可能になる。そのメカニズムをわかりやすく説明するために、以下の問題設定を考える。学習前のデータ全体を2つの部分集合 U と L で表すことにする。ラベル付けされていないデータ群を U 、既にラベル付けされたデータ群を L と表記する。一般的には、部分集合 U が L よりずっと大きく、また L を手に入れるのはコストがかかる。Active Learning では最初にラベル付けされた少数のデータ L の情報を基に、分類器あるいは分類器のアンサンブルを学習する。その後、まだラベル付けされていないデータ U から、データの情報量の尺度（エントロピーなど）によって、最も曖昧であると判定されたデータに対してラベル付けを行なう。選ばれたデータにラベル付けが行なわれると、そのデータを L に入れ、新しいデータの入った L により再度 U の中からラベル付けを行なうデータを選ぶ。このような処理を繰り返していくことで、ラベル付けの数を増やし、認識率を高めていく。

高い認識精度を得るために、画像をどのように表現するかが重大な問題である。近年、画像をその画像から抽出された局所特徴量の集合として表すのが非常に有効なアプローチであることが様々なアプリケーションで証明されている。このような表現を用いた画像データに active learning を適用するには、上記の情報量の尺度に使用できる、全ての局所特徴量の情報を一つの評価基準として定義することが必要である。本研究では、このような評価基準をいくつか提案し、医用画像や他の一般的な画像認識問題に当てはめた。一つの例として、Dirichlet 分布に基づいた評価基準について説明する。まず、各特徴量が、確率的 classifier（分類器）から得た各クラスに属する確率を表す確率質量関数（PMF）に射影される。その後、Dirichlet 分布を用いて、query 画像の情報量の尺度を全ての特徴量の PMF から推定する。

(2) 上記（1）の結果から、このような表現がアンサンブル学習にも有効であることが

わかった. アンサンブル学習^[4]とは, 多数の弱い学習機をそれぞれ異なるデータあるいは特徴量の部分集合を用いて学習し, 各弱学習機の情報を統合することによって強い学習機を生成できる, という機械学習手法である. 情報統合は普段単純な平均で行われているケースが多いが, 本研究では Random Forest (多数の決定木を用いたアンサンブル学習の一種) における compound Dirichlet 分布に基づいた情報統合のアルゴリズムを提案した. この手法を用いて, 図 1 に示されたバイオや医用画像の自動診断システムの開発も行った. 特徴量としては, 各ピクセルを中心に, texton マップから texture と local context 関連情報を抽出する local context 特徴量を使用する. local context 特徴量は非常に高次元の特徴量であるから, 識別能力も高く, また数も多い. ランダムフォレストはこのような特徴量を overfitting せずに扱うことができるので, 少数の学習画像を用いても高い認識精度を得ることができる.

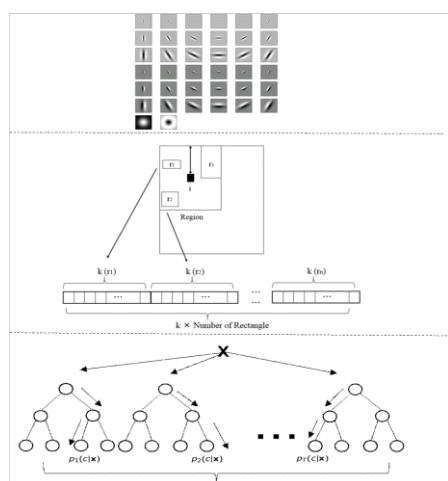


図 1. システム概要: (上) 方向微分フィルタバンクを用いて, 画像から texture 関連情報を抽出し, texton マップを作製する; (中) local context 特徴量を抽出する; (下) local context 特徴量を用いて Random Forests を学習し, 各決定木の情報を統合するには提案手法を利用する.

更に, このアルゴリズムではピクセルレベルの分類ができるので, 全画像単位で学習行う手法と比べて, 提案手法の方は一般性が高く, 学習セットの具体的なパターンには依存しない. またビデオデータにも当てはめることができるから, 実世界の自動診断には適しているともいえる.

提案手法を用いた自動診断システムの出力例を図 2 に示す.

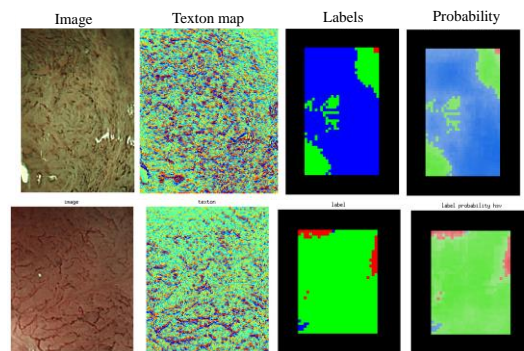


図 2. 内視鏡検査によって得られた Narrow Band Imaging (NBI) 画像を用いて, 大腸癌の自動診断を行う.

図 2 の一行目には Type C3(進行癌)の画像例, 二行目には Type B(腫瘍)の画像例を示す. 一列目の画像の血管構造に基づいて, 自動的に病状を推定するのが目的である. 二列目に, 元の画像から抽出された texton map を表示する. 3 列目と 4 列目には提案手法の結果を示す (3 列目にはラベルが離散的であるに対して, 4 列目には確率的に決められたクラスラベルが表示されている). クラス情報を色で表す. 赤: Type A(正常), 緑: Type B(腫瘍), 青: Type C3(進行癌).

図 2 からわかるように, 提案手法では少数の学習画像を用いても, かなり高い認識精度を得ることができる. 実験結果により, クラス毎に 90 枚程度の学習画像を用いたら, 90% 平均認識率を得ることができる. すなわち提案手法によって, 学習に必要なラベル付けされた学習用画像数を大幅に削減できることがわかる.

<引用文献>

- [1] K. Gono, T. Obi, M. Yamaguchi, N. Oyama, H. Machida, Y. Sano, S. Yoshida, Y. Hamamoto, T. Endo, Appearance of Enhanced Tissue Features in Narrow-Band Endoscopic Imaging. *Journal of Biomedical Optics*, Vol. 9, pp. 568-577, 2004.
- [2] H. Kanao, S. Tanaka, S. Oka, M. Hirata, S. Yoshida, K. Chayama, Narrow-band imaging magnification predicts the histology and invasion depth of colorectal tumors. *Journal of Gastrointestinal Endoscopy*, Vol. 69, No. 3, Part. 2, pp. 631-636, 2009.
- [3] B. Settles, Active Learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, Morgan & Claypool, Vol. 6, No. 1, pp. 1-114, 2012.

[4] C. Zhang and Y. Ma (eds.), Ensemble Machine Learning: Methods and Applications, Springer, 2010.

5. 主な発表論文等

(研究代表者, 研究分担者及び連携研究者には下線)

[雑誌論文] (計 1 件)

- ① A. Masuda, B. Raytchev, T. Kurita, T. Imamura, M. Suzuki, T. Tamaki and K. Kaneda, Automatic Detection of Good/Bad Colonies of iPS Cells Using Local Features, Springer Lecture Notes in Computer Science LNCS 9352, MLMI2015, pp. 153-160, 2015. 査読有 DOI: 10.1007/978-3-319-24888-2_19

[学会発表] (計 5 件)

- ① 増田 淳基, Bisser Raytchev, 栗田 多喜夫, 今村 享, 鈴木 理, 玉木 徹, 金田 和文, 「局所特徴量を用いた iPS 細胞の分化・未分化検出」, 第 18 回画像の認識・理解シンポジウム (MIRU2015), 2015/7/28--2015/7/30, ホテル阪急エキスポパーク, 大阪 (2015).
- ② M. Minakawa, B. Raytchev, T. Tamaki and K. Kaneda, Image Sequence Recognition with Active Learning Using Uncertainty Sampling, in Proc. IEEE International Joint Conference on Neural Networks (IJCNN2013), pp.2531-2536, Dallas, USA, August 4-9, 2013.
- ③ 皆川 雅俊, Bisser Raytchev, 玉木 徹, 金田 和文, 「画像列を用いた物体認識への Active Learning の適用」, 第 19 回画像センシングシンポジウム SSII2013, パシフィコ横浜, 神奈川 (2013 06).
- ④ 片本 良成, Bisser Raytchev, 糺場 未来, 玉木 徹, 金田 和文, 「アンサンブル学習に基づく Local Learning に関する研究」, 第 19 回画像の認識・理解シンポジウム (MIRU2016), 2016/8/1-2016/8/4, アクトシティ浜松, 静岡県浜松市 (2016).
- ⑤ 田中 孝二郎, Bisser Raytchev, 玉木 徹, 金田 和文, 小出 哲士, 吉田 成人, 三重 野寛, 田中 信治, 「深層学習を用いた大腸 NBI 内視鏡画像認識」, 第 19 回画像の認識・理解シンポジウム (MIRU2016), 2016/8/1 - 2016/8/4, アクトシティ浜松, 静岡県浜松市 (2016).

[その他]

ホームページ等

<http://vis.hiroshima-u.ac.jp/publications/publications.php>

6. 研究組織

(1) 研究代表者

ライチェフ ビセル (RAYTCHEV, Bisser)
広島大学・工学研究科・助教

研究者番号: 00531922