

## 条件付き確率場による医用画像からの臓器抽出に関する予備的検討

二村 幸孝<sup>†</sup> 林 雄一郎<sup>†</sup> 北坂 孝幸<sup>††</sup> 森 健策<sup>†</sup><sup>†</sup> 名古屋大学情報連携統括本部<sup>††</sup> 愛知工業大学情報科学部E-mail: [ynimura@mori.m.is.nagoya-u.ac.jp](mailto:ynimura@mori.m.is.nagoya-u.ac.jp)

**あらまし** 本稿では、条件付き確率場による医用画像からの臓器領域抽出に関して検討する。これまで医用画像からの臓器領域自動抽出を目的とした多くの研究が報告されている。しかしながら、それらの多くは経験的に決定する調整パラメータを含むといった問題が存在する。本報告では、臓器領域抽出を医用画像全体にわたる各画素の臓器ラベル推定問題ととらえ、構造学習によりパラメータを学習した確率的グラフィカルモデルに基づいて、臓器領域を自動抽出する手法に関して検討する。確率的グラフィカルモデルにはランダムに画素間を接続した条件付き確率場、特徴量には画素の濃度値と臓器ラベルの関係を表すバイナリ特徴を使用する。また、条件付き確率場のパラメータ学習には確率的勾配降下法、臓器ラベル推定には最大事後確率推定を使用する。本手法を腹部造影 CT 画像 5 例へと適用した結果、臓器ラベル推定誤差 10.0% (一致度: 肝臓 0.65, 脾臓 0.61, 右腎臓 0.61, 左腎臓 0.63, 膵臓 0.24) で、臓器領域の自動抽出が可能であることが確認された。

**キーワード** 構造学習, 条件付き確率場, セグメンテーション

## A Preliminary Study on Organ Segmentation using Conditional Random Fields from Medical Image

Yukitaka NIMURA<sup>†</sup>, Yuichiro HAYASHI<sup>†</sup>, Takayuki KITASAKA<sup>††</sup>, and Kensaku MORI<sup>†</sup><sup>†</sup> Information and Communication Headquarters, Nagoya University<sup>††</sup> Faculty of Information Science, Aichi Institute of TechnologyE-mail: [ynimura@mori.m.is.nagoya-u.ac.jp](mailto:ynimura@mori.m.is.nagoya-u.ac.jp)

**Abstract** This paper describes an organ region segmentation method using conditional random fields from medical images. A lot of methods have been proposed to enable automated extraction of organ regions from medical images. However, it is necessary to adjust empirical parameters of them to obtain precise organ regions. In this paper, we propose an organ segmentation method using structured output learning which is based on probabilistic graphical model. The proposed method utilizes randomly connected conditional random fields as probabilistic graphical model and binary features which represent the relationship between voxel intensities and organ labels. Also we optimize the weight parameters of conditional random fields using stochastic gradient descent and estimate organ labels using maximum a posteriori estimation. The experimental result revealed that the proposed method can extract organ regions automatically using structured output learning. The error of organ label estimation was 10.0%. DICE coefficients of liver, spleen, right kidney, left kidney, and pancreas are 0.65, 0.61, 0.61, 0.63, 0.24, respectively.

**Key words** structured output learning, conditional random fields, segmentation

## 1. はじめに

医用画像からの臓器領域抽出は計算機による診断支援・治療支援において非常に重要な役割を占める。そのため、これまで医用画像からの臓器領域自動抽出を目的とした多くの研究が報告されている。

Park ら [1] と Shimizu ら [2] は臓器存在確率アトラスを利用した CT 画像からの腹部臓器領域自動抽出手法を提案している。これらの手法では、複数の教師データ (CT 画像と手動で作成された臓器ラベル画像の組) から、解剖学的統計情報として、各画素位置における臓器の存在確率を表現した臓器存在確率アトラスを事前に構築する。また、臓器の存在確率に加えて、臓器形状を考慮した手法 [3], [4] や個人間の臓器形状差を考慮した手法 [5] も提案されている。これらの手法は解剖学的統計情報を利用することで、高精度かつ個人差に頑健な臓器領域の自動抽出が可能である。しかし、教師データからの臓器存在確率アトラスの構築には、画像間位置合わせ [6] や解剖学的特徴点 [7], あるいは粗抽出された臓器領域に基づく、格正規化や空間正規化を必要とする。また、臓器存在確率アトラスを利用した手法の多くは、独自に設計した目的関数をグラフカット [8] や QPBO [9] などの離散最適化手法により最小化することで臓器領域を抽出している。しかしながら、これらの目的関数には複数の調整パラメータが含まれており、これらの値は経験的に決定する必要がある。

一方で、離散最適化手法は、マルコフ確率場 (Markov Random Field, MRF) [10] や条件付き確率場 (Conditional Random Field, CRF) [11] などの確率的グラフィカルモデル [12] の最大事後確率推定においても広く利用されている。確率的グラフィカルモデルは、複数の確率変数の同時確率や条件付き確率を扱うためのモデルであり、出力が構造を有する問題における機械学習 (構造学習) で利用されている [13]。

本報告では、臓器領域抽出を医用画像全体にわたる各画素の臓器ラベル推定問題ととらえ、確率的グラフィカルモデルに基づく構造学習により、臓器領域を自動抽出する手法に関して検討する。これにより、目的関数における経験的パラメータを排除することが可能となる。また、特徴量として臓器存在確率アトラスのような絶対位置情報を利用するのではなく臓器ラベルの相対位置情報を利用することで、空間正規化を必要としない臓器領域自動抽出手法の開発を目指す。以下、2 章で提案手法の概要、3 章で実験に関して述べ、4 章で考察を加える。

## 2. 提案手法

### 2.1 概要

本稿では、CT 画像を画素と画素間の接続からなる確率的グラフィカルモデルと捉え、各画素の濃度値と臓器ラベルの関係を学習することで、新規 CT 画像における臓器ラベルを推定する。確率的グラフィカルモデルには、スパースに画素間を接続した CRF、特徴量には濃度値と臓器ラベルの関係を使用する。また、CRF の重みパラメータの学習は確率的勾配降下法 [14] に、臓器ラベル推定は最大事後確率推定に、それぞれ基づいて




図 1 特徴量. (a) 濃度値と臓器ラベルの関係, (b) 臓器ラベルと近傍の臓器ラベルの関係, (c) 濃度値と臓器ラベル, 近傍の臓器ラベルの関係を利用する。

行う。以下、(A) 前処理, (B) CRF による臓器ラベルの確率的グラフィカルモデル, (C) 最大事後確率推定による臓器ラベル推定, および (D) 確率的勾配降下法によるパラメータ学習, に関して詳述する。

### 2.2 前処理

計算量削減のため、スーパーボクセルによる CT 画像の低解像度化を適用する。本稿では、スーパーボクセルに Achanta らにより提案されている SLIC を使用する [15]。また、スーパーボクセルの臓器ラベルには、そのスーパーボクセルに含まれる全画素の最頻臓器ラベルを使用する。なお、以降の節にはおいては、スーパーボクセルを単に画素と表現する。

### 2.3 確率的グラフィカルモデル

本報告では、ある画像  $\mathbf{x}$  における臓器ラベル  $\mathbf{y}$  の事後確率  $p(\mathbf{x}|\mathbf{y})$  を CRF に基づき

$$p(\mathbf{x}|\mathbf{y}) = \frac{1}{Z(\mathbf{x})} \exp \left\{ \sum_i \sum_k w_k \psi_k(x_i, y_i) + \sum_i \sum_{j \in \mathcal{N}_i} \sum_k v_k \phi_k(x_i, y_i, y_j) \right\} \quad (1)$$

として表現する。ここで  $Z(\mathbf{x})$  は

$$Z(\mathbf{x}) = \sum_{\mathbf{y}'} \exp \left\{ \sum_i \sum_k w_k \psi_k(x_i, y'_i) + \sum_i \sum_{j \in \mathcal{N}_i} \sum_k v_k \phi_k(x_i, y'_i, y'_j) \right\} \quad (2)$$

であり、あらゆる臓器ラベル配置においてスコアを計算した正規化のための項であり、分配関数と呼ばれる。  $i, j$  は画素を表す添え字、  $\mathcal{N}_i$  は画素  $i$  の近傍画素の集合、  $x_i$  および  $y_i$  は各画素における濃度値と臓器ラベルである。また、  $\psi_k$  および  $\phi_k$  は注目画素  $i$  におけるバイナリ特徴、  $k$  はそれらの添え字、  $w_k$  および  $v_k$  はその特徴に対する重みパラメータである。本報告では、  $\psi_k$  として  $1_{\{x_i=o\}} 1_{\{y_i=s\}}$  を  $\phi_k$  として  $1_{\{y_i=s\}} 1_{\{y_j=t\}}$  および  $1_{\{x_i=o\}} 1_{\{y_i=s\}} 1_{\{y_j=t\}}$  を使用する (図 1)。ここで、  $1_{\{\cdot\}}$  は括弧内の条件を満たす場合に 1、満たさない場合に 0 を出力する関数である。  $o$  は濃度値を、  $s$  および  $t$  は臓器ラベルを表し、その組み合わせは各バイナリ特徴の添え字  $k$  により一意に決定される。

近傍画素集合  $\mathcal{N}_i$  は、注目画素  $i$  から一定範囲内に位置する画素をランダムに選択する (図 2.3)。具体的には、必要とする近傍画素数  $N$  の相対位置ベクトルを、半径  $R$  の球内の一様分布に従い予め作成しておき、注目画素  $i$  の位置に応じて近傍画




図2 近傍画素の例。(a) 各画素の近傍画素は注目画素からの相対位置により定義される。(b) 他の画素においても同様の位置関係で近傍画素を定義する。2.3

素  $j$  を決定する。これにより、図 (b) に示すように、全画素において同様の近傍画素を定義することが可能となる。

## 2.4 臓器ラベル推定

本手法では、与えられた画像  $\mathbf{x}$  に対する事後確率  $p(\mathbf{y}|\mathbf{x})$  を最大化する臓器ラベル  $\hat{\mathbf{y}}$  を推定臓器ラベルとして出力する。重みパラメータ  $w_k$  および  $v_k$  が既知である場合、画像  $\mathbf{x}$  に対する推定臓器ラベル  $\hat{\mathbf{y}}$  は、最大事後確率推定

$$\hat{\mathbf{y}} = \operatorname{argmax}_{\mathbf{y}} p(\mathbf{y}|\mathbf{x}) \quad (3)$$

により得ることができる。しかしながら、事後確率  $p(\mathbf{y}|\mathbf{x})$  の計算には、分配関数  $Z(\mathbf{x})$  を計算する必要があるため、効率的に最大化することは困難である。そこで本稿では、事後確率  $p(\mathbf{y}|\mathbf{x})$  の代わりに、平均場近似 [12] による事後確率の近似  $q(\mathbf{y}|\mathbf{x})$  を利用する。平均場近似では、各画素において臓器ラベル  $y_i$  の事後確率の近似  $q_i(y_i|\mathbf{x})$  が独立であると仮定し、更新式

$$q_i(y_i|\mathbf{x}) \leftarrow \frac{1}{Z_i} \exp \left\{ \sum_k w_k \psi_k(x_i, y_i) + \sum_{\mathbf{y}'} \sum_{j \in \mathcal{N}_i} \sum_k v_k \phi_k(x_i, y_i, y_j') q_j(y_j'|\mathbf{x}) \right\} \quad (4)$$

を繰り返し適用することで、各画素における  $q_i(y_i|\mathbf{x})$  を算出する。ここで、 $Z_i$  は正規化のための項である。この更新は、全ての画素において  $q_i(y_i|\mathbf{x})$  が変化しなくなるまで繰り返し適用する。なお、初期値は

$$q_i(y_i|\mathbf{x}) \leftarrow \frac{1}{Z_i} \exp \left\{ \sum_k w_k \psi_k(x_i, y_i) \right\} \quad (5)$$

として与える。これにより、画像  $\mathbf{x}$  全体に対するの最大事後確率推定は、各画素に対する最大事後確率推定

$$\hat{y}_i = \operatorname{argmax}_{y_i} q_i(y_i|\mathbf{x}) \quad (6)$$

へと近似できる。ここで、 $\hat{y}_i$  は画素  $i$  における推定臓器ラベルである。

## 2.5 パラメータ学習

各特微量に対する重みパラメータ  $w_k$ ,  $v_k$  は、画像  $\mathbf{x}$  とその臓器ラベル  $\mathbf{y}$  から計算される  $p(\mathbf{y}|\mathbf{x})$  の対数尤度

$$L = \log p(\mathbf{y}|\mathbf{x}) = \sum_i \sum_k w_k \psi_k(\mathbf{x}, \mathbf{y}) + \sum_i \sum_{j \in \mathcal{N}_i} \sum_k v_k \phi_k(x_i, y_i, y_j) - \log Z(\mathbf{x}) \quad (7)$$

を最大化することで推定できる。本報告では確率的勾配降下法 [14] により逐次的に重みパラメータを更新することで上記式を最大化する。確率的勾配降下法では、全ての教師データを一度に利用するのではなく、単一の教師データのみから算出される対数尤度  $L$  の勾配を利用する。本稿では、更新式

$$w_k \leftarrow w_k + \alpha \frac{\partial L}{\partial w_k}, \quad (8)$$

$$v_k \leftarrow v_k + \alpha \frac{\partial L}{\partial v_k}, \quad (9)$$

を各教師データに対して逐次的に適用することで重みパラメータを学習する。ここで、 $\alpha$  ( $\alpha > 0$ ) は学習係数である。 $w_k$  および  $v_k$  に対する対数尤度  $L$  の偏微分は、

$$\frac{\partial L}{\partial w_k} = \sum_i \psi_k(x_i, y_i) - \sum_{\mathbf{y}'} \sum_i \phi_k(x_i, y_i) p_i(y_i'|\mathbf{x}), \quad (10)$$

および、

$$\frac{\partial L}{\partial v_k} = \sum_i \sum_{j \in \mathcal{N}_i} \phi_k(x_i, y_i, y_j) - \sum_{\mathbf{y}'} \sum_i \sum_{j \in \mathcal{N}_i} \phi_k(x_i, y_i', y_j') p_i(y_i'|\mathbf{x}) p_j(y_j'|\mathbf{x}) \quad (11)$$

であり、 $p_i(y_i|\mathbf{x})$  は  $y_i$  の周辺確率である。本稿では、これらの値に関しても、平均場近似により得られた  $q_i(y_i|\mathbf{x})$  を使用する。なお、 $w_k$  および  $v_k$  の初期値は 0 とする。

## 3. 実験

本稿で述べた手法の有効性を確認するために、体幹部造影 CT 画像 5 例に本手法を適用し、Leave-one-out 法を用いて推定臓器ラベルの一致度 (Dice Coefficient, DC) を評価した。実験に使用した CT 画像の仕様は、画像サイズ  $512 \times 512 \times 641 \sim 701$  voxels, 解像度  $0.732 \times 0.732 \times 1.0 \sim 0.919 \times 0.919 \times 1.0 \text{ mm}^3$ , 管電圧 120 kVp, 管電流 110 ~ 300 mAs である。なお、対象臓器は体幹部に存在する 35 種類の領域 (表 1) とし、学習および評価に使用した臓器ラベルは解剖学的知識を有する工学関係者が手作業により作成した。実験には  $\alpha$  として 0.5 を使用し、近傍画素数  $N$  は 256, 近傍範囲  $R$  は 512 mm とした。

表 1 に提案手法により推定された臓器領域と正解臓器領域の一致度、図 3 に学習回数と臓器ラベル推定誤差の関係、図 4 に学習回数と一致度の関係を示す。また、図 5 は臓器ラベル推定結果例である。臓器ラベル推定誤差は学習回数 20 回で 10.0% であった。なお、臓器ラベル推定には CPU: Intel Xeon X5660  $\times$  2, Memory: 24 GBytes の計算機において一症例あたり 2 時間程度の時間を必要とした。

表 1 臓器領域の平均一致度. TPR: True Positive Rate, PPV: Positive Predictive Value, DC: DICE Coefficient.

Organ	TPR	PPV	DC
右肺	0.92	0.73	0.79
左肺	0.90	0.73	0.78
心臓	0.65	0.71	0.67
大動脈	0.47	0.27	0.34
食道	0.60	0.06	0.11
肝臓	0.60	0.80	0.65
胆嚢	0.82	0.11	0.19
胃・十二指腸	0.42	0.26	0.31
脾臓	0.76	0.53	0.61
右腎臓	0.76	0.53	0.61
左腎臓	0.73	0.56	0.63
下大静脈	0.49	0.20	0.27
門脈・脾動脈・上腸間膜静脈	0.21	0.12	0.13
膵臓	0.51	0.18	0.24
膀胱	0.86	0.15	0.25
子宮	0.51	0.25	0.28
椎骨	0.56	0.66	0.60
椎間板	0.47	0.13	0.20
小腸・大腸	0.43	0.23	0.29
大腿骨(左)	0.72	0.50	0.56
大腿骨(右)	0.72	0.48	0.54
骨盤(左)	0.59	0.53	0.55
骨盤(右)	0.55	0.53	0.52
左上腕骨	0.63	0.14	0.23
右上腕骨	0.69	0.15	0.24
左肩甲骨	0.70	0.52	0.60
右肩甲骨	0.65	0.50	0.56
左鎖骨	0.58	0.17	0.26
右鎖骨	0.56	0.16	0.24
肋骨(左)	0.53	0.38	0.44
肋骨(右)	0.59	0.43	0.47
胸骨・肋軟骨	0.62	0.25	0.35
筋肉	0.72	0.75	0.74
他組織	0.81	0.92	0.86
体外	0.97	1.00	0.98

#### 4. 考 察

表 1 および図 5 より, 提案手法により臓器領域抽出が可能であることが読み取れる. しかしながら, 肝臓, 脾臓, 右腎臓, 左腎臓, および膵臓領域の一致度が, それぞれ 0.65, 0.61, 0.61, 0.63, 0.24 であり, 臓器全般で低い一致度であった. 肝臓における低一致度は, TPR 0.60, PPV 0.80 であることから, 多数の未抽出画素が原因である. これは図 5 (e) において, 肝臓画素を胃画素あるいは筋肉画素と誤って推定していることから確認できる. 一方で, 膵臓における低一致度は PPV 0.18 と非常に低く, こちらは多数の過抽出画素に起因している. これらの問題の解決には, 形状に対する制約を特徴量へ加えることで解決できると考えられる.

図 5 (a)-(c) では肺野領域における過抽出・未抽出画素が確認できる. 特に多くの結果において, 肺野画素が体外に存在す




図 3 学習回数と臓器ラベル推定誤り率の関係.

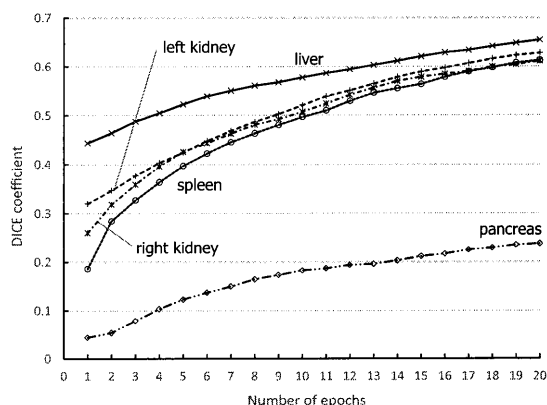


図 4 腹部臓器における学習回数と一致度の関係.

るとい問題が発生しており, 肺野領域の一致度低下の原因となっている. これらの過抽出・未抽出画素は, 孤立した小領域として存在しており, 平滑化項あるいは平滑化に関する特徴量の導入など各臓器領域の連続性を考慮することで対処可能と考えられる.

図 3 は学習回数による臓器ラベル推定誤り率の変化を表したグラフである. 学習回数の増加により臓器ラベル推定の精度が向上していることが読み取れる. なお, 誤り率の計算には画素の大多数を占める体外画素の推定精度も含まれている. そこで, 各臓器の推定精度の変化を確認するため, 腹部臓器における学習回数と一致度の関係についても調査した(図 4). 図から, 学習回数の増加に応じて臓器領域の一致度が向上していることが確認できる. しかしながら, 一致度は学習回数 20 回以降も向上すると考えられ, より多くの学習回数での一致度評価が必要である.

本手法は, ランダムに定義した近傍画素においてのみの臓器間関係を構造学習に使用している. より詳細な評価のために, 近傍画素の数や近傍画素の定義方法(等間隔や正規分布など), 対象臓器数などを変化させた際の振る舞いを調査する必要がある.


## 5. むすび

本稿では、医用画像からの条件付き確率場に基づく臓器自動抽出手法に関して検討した。実験の結果、構造学習を臓器ラベル推定に利用可能であることが確認された。今後の課題は、学習係数と推定精度の関係調査、平滑化項の導入による臓器抽出精度の向上、対象臓器の拡充、大規模データを使用した評価があげられる。


**謝辞** 日頃より熱心な御討論頂く名古屋大学森研究室の諸氏に感謝いたします。なお本研究の一部は、文部科学省・日本学術振興会科学研究費補助金 21103001, 21103006, 25242047, 栢森情報科学振興財団研究助成金, および日本学術振興会二国間交流事業 (共同事業) による。

## 文 献


- [1] H. Park, P. Bland, C. Meyer, "Construction of an abdominal probabilistic atlas and its application in segmentation," *IEEE Transactions on Medical Imaging*, vol.22, no.4, pp.483-492, 2003.
- [2] A. Shimizu, R. Ohno, T. Ikegami, et al., "Segmentation of multiple organs in non-contrast 3D abdominal CT images," *International Journal of Computer Assisted Radiology and Surgery*, vol.2, no.3-4, pp.135-142, 2007.
- [3] A. Shimizu, T. Kimoto, H. Kobatake, et al., "Automated pancreas segmentation from three-dimensional contrast-enhanced computed tomography," *International Journal of Computer Assisted Radiology and Surgery*, vol.5, no.1, pp.85-98, 2010.
- [4] M.G. Linguraru, J.A. Pura, V. Pamulapati, et al., "Statistical 4D graphs for multi-organ abdominal segmentation from multiphase CT," *Medical Image Analysis*, vol.16, no.4, pp.904-914, 2012.
- [5] C. Chu, M. Oda, T. Kitasaka, et al., "Multi-organ Segmentation Based on Spatially-Divided Probabilistic Atlas from 3D Abdominal CT Images," *International Conference on Medical Image Computing and Computer Assisted Intervention, LNCS*, vol.8150, pp.165-172, 2013.
- [6] D. Ruckert, L. Sonoda, C. Hayes, et al., "Nonrigid registration using free-form deformations: application to breast mr images," *IEEE Transactions on Medical Imaging*, vol.18, no.8, pp.712-721, 1999.
- [7] S. Hanaoka, Y. Masutani, M. Nemoto, et al., "Automatic categorization of anatomical landmark-local appearances based on diffeomorphic demons and spectral clustering for constructing detector ensembles," *International Conference on Medical Image Computing and Computer Assisted Intervention, LNCS*, vol.7511, pp.106-113, 2012.
- [8] Y. Boykov, O. Veksler, R. Zabih, "Fast approximate energy minimization via graph cuts," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol.23, no.11, pp.1222-1239, 2001.
- [9] C. Rother, V. Kolmogorov, V. Lempitsky, et al., "Optimizing binary MRFs via extended roof duality," *IEEE Conference on Computer Vision and Pattern Recognition*, pp.1-8, 2007.
- [10] R. Kindermann, J.L. Snell, *Markov Random Fields and Their Applications*, American Mathematical Society, 1980.
- [11] J. Lafferty, A. McCallum, F. Pereira, "Conditional random fields: probabilistic models for segmenting and labeling sequence data," *Proceedings of International Conference on Machine Learning*, pp.282-289, 2001.
- [12] D. Koller, N.Friedman, *Probabilistic Graphical Models: Principles and Techniques*, The MIT Press, 2009.
- [13] T. Kudo, K. Yamamoto, Y. Matsumoto, "Applying Conditional Random Fields to Japanese Morphological Analysis," *Proceedings of the 2004 Conference on Empirical Methods in Natural Language Processing*, pp.230-237, 2004.
- [14] L. Bottou, *Online Learning and Neural Networks*, Cambridge University Press, 1998.
- [15] R. Achanta, A. Shaji, K. Smith, et al., "SLIC Superpixels Compared to State-of-the-art Superpixel Methods," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol.34, no.11, pp.2274-2282, 2012.




(a)




(b)



(c)



(d)



(e)

図5 臓器自動抽出結果例. 左から, 入力画像, 正解臓器ラベル, 推定臓器ラベル, 推定臓器ラベルの一部を拡大したものを表す.