

1 階のデータ項を用いた多臓器同時セグメンテーション

森田 皆人^{1,a)} 岡川 明日翔¹ 小滝 将太¹ 望月 義彦¹ 小山田 雄仁¹ 石川 博^{1,b)}

概要 :

多臓器の同時セグメンテーションを CRF を用いて行う手法を提案する。従来手法では、隣接画素間の影響を与える項は事前確率のみに基づいていたが、提案手法では、入力画像に依存する条件付確率に基づいた 1 階のデータ項を用いる。真値を伴うデータセットから学習した 1 階のデータ項を用いたセグメンテーション実験の結果を報告する。

キーワード : セグメンテーション, グラフカット, エネルギー最小化

1. 医用画像セグメンテーション

本研究のセグメンテーションは、入力の医用画像の各ボクセルに、臓器の種類を表すラベルを与える。医用画像としては、CT 画像を用いる。CT 画像は、X 線 CT 装置から得られる画像である。また、本研究では、3 次元 CT 画像を用いる。これは、CT 画像スライスを、 S 枚重ねたものである。

症例ごとの身長や体の大きさによって、3 次元 CT 画像の大きさも異なっている。そのため、事前にレジストレーションを行う。これは、それぞれの CT 画像は写っている範囲が異なるということを解決するため、CT 画像のいくつかの部分を目印に画像の抜き出しを行う。そして、抜き出した画像の大きさを一定にする。このようにすることで、体の大きさなどといった個人差を解消した CT 画像を実験に用いる。

CT 画像の画素値の単位として、HU (Hounsfield unit) という単位が利用されている。これは、水を 0、空気を -1000 とする臨床目的のための単位で、以下の式にあてはめて計算をすることで、それぞれの CT 値を求めることができる。組織の X 線吸収係数を u_t とし、水の X 線吸収係数を u_w とすると、

$$\frac{u_t - u_w}{u_w} \times 1000 \quad (1)$$

と表すことができる。X 線吸収率は組織ごとに異なっているため、CT 値は組織を区別するために用いることができる [1]。

セグメンテーションの方法として、スネーク法 [2] やレベルセット法 [2] など、いくつかの種類が挙げられる。しかし、スネーク法に関しては、事前知識を導入することが難しいという問題があり、学習を用いるという点において今回のセグメンテーションに用いるのは困難であった。また、レベルセット法に関しては、抽出対象となる画像ごとに境界を更新することに関するパラメータの設定をしなければならない [3] という問題点があった。本研究でのセグメンテーションは、連続した CT 画像とその画像に対する正解ラベルデータのみを入力としたため、その点においてレベルセット法を用いることは困難であった。

本研究では、セグメンテーションの問題を解く際にエネルギー最小化の考え方を用いる。そのラベルの与え方の良さを評価するエネルギー関数を定義し、このエネルギーが最も小さくなるようなラベル付けを、セグメンテーション結果とする。

エネルギー最小化を考えるにあたり、事前に CT 画像と正解ラベルデータから学習を行う。これは、エネルギー関数を構成するデータ項とアトラス項に用いられるものである。データ項では、ラベルごとにどのような CT 値をとるかの統計をあらかじめ知っておき、その出現確率をエネルギー計算の際に用いる。アトラス項では、ラベルごとにどのボクセルで現れるかの統計をあらかじめ知っておき、その出現確率をエネルギー計算の際に用いる。

CT 画像を見たときに、画像上に写っている臓器に対し正しくラベルを与え、臓器をラベルによって区別したものを学習の際に用いる。これを、CT 画像に対する正解ラベルデータと呼ぶ。そのような画像の組の例を図 1 に表す。正解ラベルデータは、例えば骨といったような本研究でラ

¹ 早稲田大学大学院 基幹理工学研究科 情報理工・情報通信専攻
a) roll-aokage.17@ruri.waseda.jp
b) hfs@waseda.jp

ベル付けしないものは写っておらず、CT 画像に写っている臓器の位置を写したものとなっている。

従来手法のエネルギー関数は、CRF を用いて、以下のよう表す。

$$E(L) = w_g \sum_{v \in V} g(L_v) + w_a \sum_{v \in V} a(L_v) + w_h \sum_{(u,v) \in E} h_{uv}(L_u, L_v) \quad (2)$$

ここで、 g 、 a 、 h はそれぞれデータ項、アトラス項、平滑化項というものである。

データ項 g は、各ボクセルにどのラベルを与えているのかによって値が決まる項であり、そのボクセルとそこに与えられたラベルのみに依存する値となる。あるボクセルに対しラベルが与えられたとき、そのラベルがそのボクセルが持つ CT 値 に対してどれほどの出現確率を持つのかによって、値が変わっていく。

アトラス項 a は、ある程度の個人差は存在するものの、人間の臓器の大まかな位置や大きさなどはある程度決まっているという前提にもとづいて設計されたエネルギー項である。ラベルが与えられたとき、そのボクセルに対して、そのラベルの出現確率がどれほどであるかを用いる。そして、出現確率が大きいほどエネルギーが小さくなるというエネルギー項の設計が行われている。

平滑化項 h は、隣接するボクセル間でラベルがどのような関係にあるべきかという前提を反映したものである。事前知識として、「画像はあまり激しく変化しない」というものがあるので、隣接するボクセルのラベルが異なっていた場合にエネルギーが増加するというものになっている。本研究では、Potts エネルギーと呼ばれるものを用いている。具体的には、以下の式 (3) で定義される。

$$h_{uv}(L_u, L_v) = \begin{cases} 1 & (L_u \neq L_v) \\ 0 & (L_u = L_v) \end{cases} \quad (3)$$

V はラベルが振り分けられるボクセルの集合を表し、 $E \subset V \times V$ は、隣接したボクセルの集合である。例えば、 $(u, v) \in E$ のとき、ボクセル u と v は隣接していると考えられる。また、 L はラベルの振り分け方を表すものであり、 L_v は、ボクセル v でのラベルを表している。このとき、エネルギー項で参照するボクセルの数から 1 を引いたものを、エネルギーの階数と呼ぶ。ここでは、データ項とアトラス項は 0 階のエネルギー、平滑化項は 1 階のエネルギーとなる。式 (2) の重み w_g 、 w_a 、 w_h はそれぞれのエネルギー項の影響力を調整するものである。よって、重みを適切につけることは適切なセグメンテーション結果の為に不可欠なものである。

1.1 グラフカットを用いた CT 画像のセグメンテーション

本研究では、グラフカットを用いたエネルギー最小化を

考える。グラフカットは、エネルギー最小化を考える際に用いられるアルゴリズムの一つである。グラフカットの利点としては、一つは実行時間が運用可能な程度に収まるということである。もう一つは、条件がある程度決まっているが、値が大域最小値に収束することが可能となっている点である。グラフカットはこれらの点で優れているといえる [4]。

式 (2) の最小化は一般には NP 困難である [4] ため、本研究では、エネルギー関数の最小化にグラフカットを用いた近似的な計算を用いる。

式 (2) のエネルギー項だけでは、すべての臓器の境界を高精度に認識することができない。そのため、様々なエネルギー項を設計してセグメンテーションを行う研究が行われている。例えば、[5] では、高階エネルギーを用いたエネルギー最小化の提案をしている。高階エネルギーとは、多くのボクセルに依存する項を含むエネルギーのことである。階数とは、エネルギー項を設計するときに参照されるボクセルの数を表しており、ボクセル数から 1 を引いたものを階数と呼ぶ。そのため、データ項、アトラス項は 0 階のエネルギー項であり、平滑化項は 1 階のデータ項である。一般的に、用いるボクセルの数を増やせばより高精度なセグメンテーションが行うことができるため、階数を増やすことは有効である。また、[6] では、腎臓を正確に抽出するために、腎臓の形状情報をエネルギー項の一つに用い、正確なセグメンテーションを可能にしている。

本研究においては、新たなエネルギー項を考える際、高階のエネルギー項を定義するのではなく、1 階のエネルギー項においてよりよいセグメンテーションに貢献できるエネルギー項を設計することを試みる。そのため、従来手法において 1 階のエネルギー項として用いられていた平滑化項を改良することを試みる。

従来手法におけるエネルギー項の問題点を示す具体的な例として、以下に図 1、図 2 を表す。図 1 は、ある CT 画像とそれに対応するラベルを正しく与えた画像の組である。この図において、例えば肺のような、周囲の CT 値と比較して明らかに値が異なっている臓器は、CT 値を参照するものであるデータ項を用いれば判別ができると考えられる。また、図 2 は、複数人の CT 画像に正しくラベルを与えたもののうち、同じ座標の部分を表示したものである。図 3 は、ラベル付けが行われた画像内において、ラベルの色と臓器の対応を表す。図 2 において、例として、胃 + 十二指腸、胃 + 十二指腸内容物を挙げると、これらの臓器は CT 画像によって様々な場所にあるといえるので、臓器の場所の情報を用いるアトラス項はうまく働かないと考えられる。また、図 1 から分かるように、CT 画像においての CT 値も近い値を取り、他の臓器と見分けがつかないため、従来手法では抽出が難しい臓器であると考えられる。このようなものを提案手法によって抽出することを試みる。




図 1 CT 画像とその画像に対し正しくラベル付けされた画像の組の例。左がラベル付けされた画像を表し、右が CT 画像を表す。ラベル付けされた画像において、異なる色の部分は異なる臓器を表し、例えば、赤いラベルが付けられている部分は心臓を表す。



図 2 複数症例の CT 画像の、座標が等しい断面の CT 画像をラベル付けしたものを並べたもの。両肺や肝臓といった臓器はどの症例においてもある程度位置が定まっているのに対し、心臓や胃 + 十二指腸といった臓器はそうではないといえる。

0 背景	11 胃+十二指腸内腔
1 右肺	12 胃+十二指腸内容物
2 左肺	13 脾臓
3 心臓	14 右腎臓
4 大動脈	15 左腎臓
5 食道	16 下大静脈
6 食道内腔	17 門脈+脾静脈+上腸間膜静脈
7 なし	18 膀胱
8 肝臓	19 膀胱
9 胆嚢	20 前立腺
10 胃+十二指腸(Second Portionまで)	21 子宮

図 3 ラベルの色と臓器の一覧。ラベルの種類は 22 種類存在する。




図 4 平滑化項と 1 階のデータ項の、ボクセルにラベルを与え方の違い。左の図は平滑化項のラベルの与え方を表し、右の図は 1 階のデータ項のラベルの与え方を表す。平滑化項は隣接するボクセルのラベルが同じになるようにラベルを与えることに対し、1 階のデータ項は CT 値に基づくラベルを与える。

1.2 提案手法のアイデア

本研究では、従来手法との違いとして、平滑化項の代わりに、新しいエネルギー項を設計する。これは、注目ボクセルと隣接ボクセルとの 2 ボクセル分のラベル値ごとの CT 値の出現確率を用いたものを新たにエネルギー項の一つとするというものである。

この論文では、提案したエネルギー項を 1 階のデータ項と呼ぶ。このエネルギー項を用いた結果として、隣接臓器の境界をより高精度に認識できることが期待できる。

平滑化項と 1 階のデータ項の違いを図 4 に表す。図において、左のものが平滑化項のラベル付けのイメージ、右のものが 1 階のデータ項のラベル付けのイメージである。従来手法で用いられていた平滑化項は、式 (3) で表されるように、隣接する 2 ボクセルのラベルを同じにするよう設計された potts エネルギーを用いる項であった。このエネルギー項は、CT 値や位置情報といった事前情報を用いることはできない。それに対し、提案手法で用いる 1 階のデータ項は、データ項と同様に、学習した CT 値を用いることができる。与えられるラベルが二値の場合においては、平滑化項を用いることで、ラベルの境目を滑らかにすることが有用であるが、本研究では多臓器に対するセグメンテーションであるので、ラベルが多値である。よって、平滑化項を用いるよりも 1 階のデータ項を用いたほうがよい結果が出ると予期される。

また、従来手法のデータ項と提案手法の 1 階のデータ項の違いを図 5 に表す。左の図は従来のデータ項の CT 値に対する出現確率の分布のイメージを表し、右の図は 1 階のデータ項の 2 ボクセルの CT 値に対する出現確率の分布のイメージを表す。従来手法のデータ項の問題点として、出現確率を計算したときに、CT 値に対する出現確率の分布が似たような臓器が存在することが挙げられる。このような臓器が存在すると、データ項でのラベル付けは全て最も出現確率が高い臓器としてラベル付けが行われてしまい、他の臓器に吸収されてしまう臓器が出てきてしまう。図においては、赤い分布と青い分布が重なっているところを表す。それに対し、提案手法のエネルギー項を用いると、隣接する臓器との関係を用いてラベル付けを行




図 5 データ項と 1 階のデータ項の判別できる分布の違い。左の図はデータ項により判別できる分布を表し、右の図は 1 階のデータ項により判別できる分布を表す。1 階のデータ項は二次元的な分布図になるため、データ項では判別できない分布を判別することが期待される。

うので、出現確率の分布が二次元的なものとなり、データ項では吸収されていた臓器が発見できるようになる。そのため、抽出できる臓器が増加すると考えられる。図で説明すると、もしも二つの臓器出現確率の分布が重なっていても、その臓器が黄色の出現確率の分布で表される臓器と隣接しており、隣接するときの出現確率の分布が異なっていれば、臓器の判別ができると考えられる。臓器の中には、CT 画像ごとに出現する位置に差があり、かつ、CT 値の分布が似ている臓器が存在する。そのため、そのような臓器を判別する際に有効であると考えられる。

2. 提案手法

2.1 提案するエネルギー項

1 項で述べたように、エネルギー最小化を考える際に、従来手法では平滑化項というものをを用いており、これは、隣接する 2 ボクセルに対し与えられたラベルが、2 ボクセル間で同じであるかどうかのみを評価するものであった。そこで、隣接した 2 ボクセルのラベル付けを考える際に、事前情報として与えられる CT 値の分布も用いることを考えた場合どのようなエネルギー関数を設計するかを考慮し、平滑化項に置き換わるエネルギー項の設計をした。そのエネルギー項は、式 (4) で表せる。

$$\sum_{(u,v) \in S} d_{L_u L_v}(I_u, I_v) \quad (4)$$

ここで、 L はラベル値を表しており、 S はボクセルの集合を表す。また、 I を CT 画像の CT 値とする。また、 u, v それぞれを体積や CT 値を持っている場所を表すボクセルとする。このとき、 u を注目ボクセルとし、 v を u の周りに隣接する隣接ボクセルとする。このとき、隣接ボクセルとは、上下左右前後に隣接するので、一つの注目ボクセルに対し 6 つ存在すると定義する。

また、この項における具体的なエネルギーの計算方法としては以下の式 (5) のようになる。

$$d_{L_u L_v}(I_u, I_v) = \sum -\log P(I_u, I_v | L_u, L_v) \quad (5)$$

この式において、 $P(I_u, I_v | L_u, L_v)$ とは、注目ボクセルと隣接ボクセルの、あるラベル値の組み合わせにおいて、CT 値の組み合わせの出現確率を計算するという意味である。ここから、どの臓器らしいかという評価を行う。

2.2 提案手法を用いたセグメンテーション

式 (4) を用いたエネルギー関数は、具体的に式 (6) で表せる。

$$E(L) = w_g \sum_{v \in V} g(L_v) + w_a \sum_{v \in V} a(L_v) + w_d \sum_{(u,v) \in S} d_{L_u L_v}(I_u, I_v) \quad (6)$$

このようなエネルギー関数を用いて、エネルギー最小化を行う。

このエネルギー関数を解く際のグラフカットのアルゴリズムとして、QPBO と融合移動が挙げられる。

QPBO とは、劣モジュラ条件が満たされない場合に、ラベル付けの問題を「解けるだけ解く」ということを目標として動作するアルゴリズムである。この性質は以下のようにになっている。

- (1) ボクセルに与えるラベルを、 $(0, 1, \phi)$ のどれかと定義する。 ϕ のラベルは「不明」を意味する。
- (2) ラベル付けについて、ラベルが不明でないもののラベル付けを X 、全てが不明であるラベル付けを Y 、ラベルが不明であるものと不明でないものが共存したラベル付けを Z とすると、常に $E(Z) \leq E(Y)$ を満たす。ここで、 Y として大域最小解をとることができれば、 X は常に大域最小解の一部にあるといえる。つまり、「不明」のボクセルにうまくラベルを振っていくことで常に大域最小値へと向かうことができる。
- (3) もし劣モジュラ条件が満たされていれば、必ず大域最小解を得ることができる。

融合移動とは、近似解を求める際の手法の一つであり、これも α 拡張と同様、あるラベル付けから別のラベル付けへの移動を定義している。具体的には、ラベル付け X について新しいラベル付け P を提案し、それぞれのボクセルについてももとのラベル付けと提案されたラベル付けのどちらを使用するかを 2 値問題とするというものである。これも 2 値のグラフカットを用いて繰り返し、提案されるラベル付けがなくなるまで繰り返す。 α 拡張との違いは、 α 拡張は提案するラベル付けにおいてラベルが一つしか選べないのに対し、融合移動は新しいラベル付けを提案するので多値の提案が可能になるという点である [7]。なお、QPBO でラベルが「不明」となっていたボクセルを融合移動では変更しないようにすると、エネルギーは増えないことが保障されている。

3. 実験

3.1 提案手法のエネルギー項に用いる確率分布の学習

3.1.1 実験目的

この実験では、エネルギー最小化に用いる学習データを作成することが目的である。学習すべきデータの特徴はいくつかあるが、本研究の提案手法では、注目ボクセルと隣接ボクセルのラベル値の組み合わせごとの CT 値の組み合わせの出現確率を利用するので、それを学習することについて述べる。

3.1.2 方法

まず、注目ボクセルと隣接ボクセルのラベル値 L_u, L_v を一通りに定める。そして、1 症例の正解データから、注目ボクセルの値が L_u 、隣接ボクセルのラベル値が L_v であるボクセルの組を探索する。もしこのようなボクセルの組が存在すれば、そのときのボクセルの CT 値を参照し、その CT 値の組み合わせがあったということをカウントしていく。このとき、CT 値を厳密に参照すると、データのノイズなどの影響を受けやすくなってしまふ。そのため、CT 値に幅を持たせ、その範囲内の CT 値はまとめてカウントしていく。これにより、ラベル値と CT 値の 4 変数に対して出現頻度が一つ求まる。あるラベル値の組み合わせにおいて正解データの中を探索し終えたら、ラベル値の組み合わせを変え、同様の手順を踏む。ラベル値は 0 から 21 までの 22 通りあるので、組み合わせの総数は 484 通り存在する。このとき、学習で用いる CT 画像と画像に対する正解ラベルデータは事前にレジストレーションを行い、大きさを一定にしたものを用いている。そのため、症例の身長や体の大きさによる個体差を考慮する必要はない。


1 症例に対する全ての組み合わせについてのカウントが終わったら、次の学習に用いる症例に対しても同様のカウントを行う。こうして、症例ごとのラベル値の組み合わせごとの CT 値の組み合わせごとの出現頻度が求まる。

人数分の出現頻度が求められたら、それを統合し、標準化することを考える。学習データは全症例分だけファイルが存在する。統合の方法として、異なる症例について学習したデータのうち、注目ボクセルと隣接ボクセルのラベル値が同じ値をとるときの CT 値の組み合わせの出現頻度の平均をとることで、複数症例の学習データを統合することができる。この処理を全ての学習した症例間で行う。

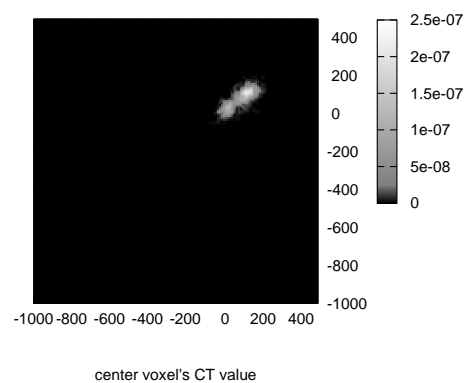
次に、標準化することを考える。現在の学習データは、出現確率ではなく出現頻度で値を保持している。これを、CT 値のビンごとの和が 1 になるように標準化する。このようにすることで、ラベルの組み合わせの出現頻度による差をなくすることができる。

3.1.3 結果

学習したデータの結果は大量に存在するので、いくつかの例の結果を紹介する。



(a) 注目ボクセルのラベルが右肺、隣接ボクセルのラベルが心臓。



(b) 注目ボクセルのラベルが右腎臓、隣接ボクセルのラベルが胃 + 十二指腸。

図 6 学習した注目ボクセルごとの出現確率。横軸は注目ボクセルの CT 値を表し、縦軸は隣接ボクセルの CT 値を表す。

図 6 を示す。これは、注目ボクセルと隣接ボクセルのラベルを定めたときの、CT 値ごとの出現確率を表す。図 6(a) は、注目ボクセルのラベルが右肺であり、隣接ボクセルのラベルが心臓であるときの出現確率を表す。続いて、図 6(b) は、注目ボクセルのラベルが右腎臓であり、隣接ボクセルのラベルが胃 + 十二指腸であるときの出現確率を表す。

これらの図において、横軸は注目ボクセルの CT 値を表し、縦軸は隣接ボクセルの CT 値を表す。また、CT 値ごとの出現確率はグレースケールで表され、出現確率が高いほど色は白くなる。

3.1.4 考察

学習結果からは、次のようなことが言える。図 6(a) と図 6(b) を比較すると、図 6(a) の方が出現確率の分布が広がっている。これは、隣接する臓器の CT 値が厳しく限定されていないためであるといえる。一方、図 6(b) においては、分布は一箇所に固まっているため、CT 値からラベルをラベル付けすることに適しているといえる。

3.2 セグメンテーション

3.2.1 実験目的

この実験では、学習データを用いたセグメンテーションを行い、従来手法よりも臓器がより多く抽出できることをねらいとする。この実験を行うことで、まず一つに、提案手法で設計されたエネルギー項が多臓器セグメンテーションに対し有用性を持っているのか確かめることが可能となる。また、従来手法であるデータ項、平滑化項、アトラス項を用いた手法と、提案手法のエネルギー項である 1 階のデータ項、データ項、アトラス項を用いたセグメンテーションの性能を比較し、どれほどの効果を上げることができるのかも実験することができる。

3.2.2 方法

まず、セグメンテーション結果を比較するために、従来手法のエネルギー項を用いたセグメンテーションを行う。

このときのセグメンテーションに用いる統計データの学習として、24 症例の CT 画像とその画像に対する正解ラベルデータのうち、セグメンテーションに用いる CT 画像以外のものを用いて学習を行う。

このときに用いるエネルギー項は、データ項、平滑化項、アトラス項である。これらの項を同時に用いるとき、重みを様々に変更し、そのときの重みを用いてセグメンテーションを行う。そして、セグメンテーションの結果の画像と、CT 画像に対して用意されている正解ラベルデータを比較し、セグメンテーション結果の正しいラベル付けがなされている割合である臓器全体の一致率や、臓器ごとの一致率を計算する。ここで、失敗例として、正解ラベルデータと、重みが適切に設定されていないときのセグメンテーション結果の比較を図 7 に示す。図の左のものは正解ラベルデータである。体表といった臓器ではないものにラベル付けをしてしまった場合のセグメンテーション結果は右の図のようになり、臓器があるところをなにもないとしてラベル付けしてしまう場合のセグメンテーション結果は図の真ん中のようになる。そのようなことが少ないように重みを設定し、最も良い一致率を出力したときのセグメンテーション結果を求める。

次に、提案手法のエネルギー項を用いたセグメンテーションを行う。このときに用いるエネルギー項は、データ項、アトラス項、1 階のデータ項である。先ほどの方法と同様に、重みを様々に変更し、臓器全体における正解ラベルデータとの一致率や、臓器ごとの一致率を求める。そして、得られた結果を比較して、提案手法を用いたときの性能の評価を行う。

3.2.3 結果

結果として、データ項、平滑化項、アトラス項を用いた時のセグメンテーション結果と、データ項、アトラス項、提案手法のエネルギー項を用いた時のセグメンテーション結果を図 8 に示す。このとき、臓器全体の正解ラベルデー




図 7 正解ラベルデータと、重みを適切に設定しなかったときのセグメンテーション結果。左端の画像は正解ラベルデータを表す。中央の画像は、アトラス項の重みが強すぎたために、本来ラベル付けをすべき臓器にラベル付けを行わなかった結果の画像を表す。右端の画像は、データ項の重みが強すぎたために、体表など本来は臓器でないものにラベル付けを行った結果の画像を表す。

表 1 従来手法と提案手法の縦軸の値と臓器の対応

臓器のラベル値	臓器
1	臓器全体
2	右肺
3	左肺
4	心臓
5	大動脈
6	食道
7	食道内腔
8	なし
9	肝臓
10	胆嚢
11	胃+十二指腸
12	胃+十二指腸内腔
13	胃+十二指腸内容物
14	脾臓
15	右腎臓
16	左腎臓
17	下大動脈
18	門脈+脾静脈+上腸間膜静脈
19	膀胱
20	膀胱
21	前立腺
22	子宮

タとの一致率と、臓器ごとの一致率、症例ごとの一致率の標準偏差を表す。図において、青い軸は従来手法による一致率を表しており、赤い軸は提案手法による一致率を表している。この二つのグラフにおいて、横軸は一致率をパーセンテージで表している。また、縦軸においての数値と臓器との対応を、表表 1 に表す。

3.2.4 考察

二つの結果を比較すると、従来手法の方が臓器全体に対する一致率は高い値を持つ。この理由として、各エネルギー項の重みの設定が不適切だったことが考えられる。一方、各臓器の一致率を見ると、たとえば大動脈の一致率は、提案手法の方がよりよい値を持つ。また、たとえば胃+十




図 8 従来手法と提案手法を用いたときのそれぞれのセグメンテーション結果。縦軸は臓器のラベルを表し、横軸は正解データとの一致率を表す。黒いバーは症例ごとの標準偏差を表す。

二指腸内容物や膵臓の一致率について比較すると、従来手法では一致率が 0% であったものが、提案手法では一致率が向上している。これは、注目ボクセルの CT 値の分布のみでは判別がつかなかった臓器が、隣接ボクセルの CT 値の分布を利用することで判別することができたためであると考えられる。

また、二つの結果の標準偏差の値を比較すると、臓器全体の一致率、右肺、左肺の一致率以外の標準偏差は、提案手法の方が小さい値をとる。正解ラベルデータに対して肺が占める割合は大きいので、肺のばらつきが臓器全体の一致率のばらつきに大きな影響を与える。そのため、臓器全体の一致率の標準偏差は従来手法の方が小さくなると考えられるが、他の臓器に対しては、提案手法は、従来手法に比べ、どの症例に対しても安定した結果を得ることが可能であると考えられる。

4. おわりに

本研究では、医用画像の多臓器同時セグメンテーションの際に、平滑化項に代えて、隣接する 2 ボクセルのラベル値の組み合わせに対する CT 値の出現確率を用いたエネルギー項を設計し、これを用いた。このとき、データ項、1 階のデータ項、アトラス項を同時に用いてセグメンテーションを行った。その結果、抽出できた臓器の種類は従来手法よりも増加した。また、得られた標準偏差について比較すると、提案手法の方が値が小さく、セグメンテーション結果が安定するという結果が得られた。

しかし、臓器全体に対する一致率は従来手法の方がよりよい値を持つため、エネルギー関数の設計などを改良していくことで、提案手法を改良することが今後の課題である。

謝辞

本研究の一部は文部科学省科学研究費補助金新学術領域研究「医用画像に基づく計算解剖学の創成と診断・治療支

援の高度化」(21103001)により行われた。

参考文献

- [1] 石田隆行・桂川茂彦・藤田広志：医用画像ハンドブック，オーム社 (2010)。
- [2] Szeliski, R.: コンピュータビジョンアルゴリズムと応用，共立出版 (2013)。
- [3] 佐藤善隆，羽石秀昭：レベルセット法を用いた医用画像セグメンテーション (領域抽出・モデリング)，電子情報通信学会技術研究報告. MI, 医用画像, Vol. 104, No. 580, pp. 1-6 (2005)。
- [4] 石川博：コンピュータビジョン最先端ガイド 1, アドコム・メディア (2008)。
- [5] 石川博：グラフカット・その後, *MIRU2013* (2013)。
- [6] Ali, A. M., Farag, A. A. and El-Baz, A. S.: Graph cuts framework for kidney segmentation with prior shape constraints, *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2007*, Springer, pp. 384-392 (2007)。
- [7] 石川博：高階グラフカット, *MIRU2009* (2009)。