

# ディープラーニングに基づく CT 画像からの複数の解剖学的構造の同時抽出

周 向榮, 藤田 広志

岐阜大学大学院医学系研究科知能イメージ情報分野 〒501-1194 岐阜県岐阜市柳戸 1-1  
(2017年3月6日受付, 2017年3月18日最終受付)

## Simultaneous segmentation of multiple anatomical structures on CT images using deep learning technique

Xiangrong ZHOU and Hiroshi FUJITA

Department of Intelligent Image Information, Graduate School of Medicine, Gifu University  
1-1 Yanagido, Gifu 501-1194, Japan

(Received on March 6, 2017. In final form on March 18, 2017)

**Abstract :** Our research group has been working on using deep learning (DL) to address a critical issue, automatic image segmentation, which is the fundamental part of medical image analysis based on computers. This review article describes the outline of our recent study as one application of the DL for multiple organ segmentations on CT images. We carry out the image segmentations as a multi-class, pixel-wise classification problem, and employ a fully convolutional network to solve this difficult classification task based on fully data-driven approach. Comparing to the previous works, our method uses an end-to-end DL approach to learn image features combined with a classifier together. As the result of image segmentations for 19 types of organs on 240 cases of 3D CT scans, our method demonstrated a comparable performance to other state-of-the-art works with much better efficiency, generality, and flexibility.

**Keywords :** Image segmentation, Deep learning (DL), Fully convolutional network (FCN), CT image

### 1. はじめに

人体の3次元解剖学的構造の理解は、病気の診断・治療・手術の前提であり、2次元の断面画像からの目視による確認には多くの時間と労力を要する。医用画像からの解剖学的構造の自動理解と臓器抽出は、計算機に基づく支援診断・手術の基盤であり、医用画像分析システムの性能に大きく影響する。解剖構造の自動抽出に関する研究が数十年にわたって行われてきたが、医療現場で広範囲での解剖構造の自動認識・抽出の応用はまだ見られていない。医療現場でのワークフローに合わせて高精度かつ高速な臓器抽出手法の実現が望まれている。

一方、医用画像からの臓器抽出手法の開発には、設計者の経験からモデルを開発し、そのアルゴリズムを作成する方針というアプローチがほとんどであった。医用画像から複雑な人体の解剖構造を精度よく抽出するためには、人間の医学知識を複雑な計算機アルゴリズムに変換する必要があり、豊富な経験と膨大な時間を要する。医療現場での要求に迅速かつ柔軟に対応するためには、画像処理手法の設計方針の改善が迫られている。すでに、従来の設計法にデータ駆動型の機械学習の技術を取り込む動きもあったが、最近では完全データ駆動型の設計方法としてのDeep Learning (DL) が注目されている。

DLは、基本的には従来の階層型ニューラルネットワークの改良版であり、自然画像認識の分野で大きな成功を取っている。画像認識は基本的には認識(分類)問題であり、従来の研究が人間の経験で決められた有限な特徴量の空間における分類器の設計に重点を置いていることに対し、DL法は画像からの特徴量の生成に着目し、分類ミスが最小となるように最適な特徴量と分類器の組み合わせを探索する。画像特徴が全ての後処理を左右するため、臓器の抽

出手法の開発にも、有効の特徴の生成が重要と考える。

筆者らは、単一の畳み込みニューラルネットワーク(CNN)の利用により、3次元CT画像における複数の臓器領域の同時抽出を試みた。本稿では、我々が提案した処理手法を解説し、CT画像を用いた実験結果を示す[1]。

### 2. CT 画像からの解剖学的構造の抽出

#### 2.1 自動抽出手法の概要

本研究では、手法の処理速度の高速化と未知症例に対する頑健性をもたせるために、処理全体の枠組みの簡素化を行う。具体的には、CT画像における解剖学構造(臓器)の自動抽出は、画像上の各画素を複数の臓器クラスへの分類問題と簡略化し、一つのカテゴリで各画素への臓器ラベル付けを実現する。従来研究に良く使われる画像雑音の除去や臓器輪郭の強調などの前処理を一切行わず、Fig.1に示すように、CT画像から複数の臓器を示すラベル画像まで直接的に変換する。

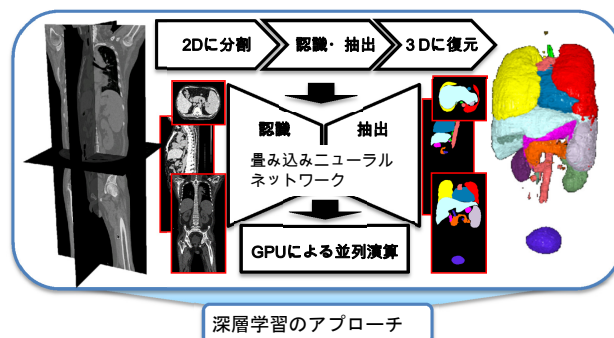


Fig.1 多臓器の自動抽出処理の流れ

## 2.2 画像特徴量

CT画像から有効な画像特徴量を獲得することは、臓器抽出を成功させる鍵である。提案手法では、人間の経験から得られた特徴量 (handcrafted features) の代わりに、DLを用いて画像から学習したもの (learned features) を使用する。各画素における特徴量の測定ではその近傍範囲で行うのが一般的であるが、本研究では、計算能力の制約のために、特徴量の測定範囲を対象画素を中心とする3次元近傍領域から、対象画素を通る三つの直交する2次元断面における6近傍に限定する。さらに、断面間の相関がないと仮定し、直交する三つの2次元断面のそれぞれから逐次的に特徴量の学習を行う。近傍領域の大きさはCNNの構造に依存されるが、本研究では各画素からの特徴量をその周辺 $32 \times 32 \times 32$  (画素) の範囲から測定することを想定する。この範囲での画像情報から膨大な数の画像特徴が生成され、各画素の分類に有効なものを選択する。

## 2.3 CNNネットワークの構造と訓練

本研究では、FCN (fully convolutional network) [2]を用いる。FCNは、ConvolutionおよびDe-convolutionと呼ばれる2種類のCNNで構成される。前者がCT画像上における各臓器の認識 (大まかの位置と範囲の決定)、後者が各臓器領域の抽出 (臓器輪郭の精細化) の役割を担う (Fig.1参照)。これら二つのCNNが有機的に結合され、各層のパラメータ (画像特徴量と判定則) を試行錯誤することによって学習が行われる。以上のように、本研究では、画素を分類するための特徴を三つの2次元断面から測定するために、FCNの入出力は2次元のCT画像とそれに対応する臓器ラベル画像である。3次元CT画像に対応するために、FCNの前後に3次元CT画像からの2次元断面のサンプリング、および複数のラベル画像 (2次元断面) から3次元図形への構成 (投票) を加え、3次元CT画像における複数の臓器領域の同時抽出を行う。

FCNの学習は、「教師あり学習」の方法を用いる。CT画像とその解剖学的構造 (複数の臓器領域のラベル画像) のペアを事前に準備し、誤差逆伝播法 (BP: back propagation) を用いて損失関数 (誤分類された画素数) が最小となるように各層のパラメータ (画像特徴量と判定則) を逐次的に調整する。深層構造のCNNの教師あり学習では、下位層のパラメータまで教師信号の影響がおよばない「勾配消滅」 (gradient vanishing) という問題があり、さらに学習に用いられるCT画像の症例数が自然画像認識の研究分野と比較して少ないので、学習の過程を工夫する必要がある。本研究では、2次元断面画像の利用による学習サンプルの数の増加、自然画像認識のために学習されたモデルを利用した転移学習を行った、また、CNNの層数を増やしながらか学習を繰り返すなどの工夫を行う。

## 3. 結果

本手法を240症例の3次元CT画像に適用して、19種類の臓器領域の抽出性能を評価した。FCNのパラメータの学習にはランダムで選択した230症例を用い、残りの10症例でFCNの性能を評価した[1]。実験ではGraphics Processing Unit (NVIDIA社製 GeForce GTX Titan X 12 GB) を使用した。Fig.2に一例を示す (文献[1]から使用許諾を得て転載)。専門家が決めた正解領域を左側に、FCNによる抽出結果を右側に表示する。10例のテスト画像の結果は、全画素の平均89%に対して正しく臓器ラベルが付けられた。また、正解領域と自動抽出結果の一致度 (19種類の臓器の体積重み付き平均値) は84%であった。主要な臓器の抽出精度 (例えば、肝臓の平均一致度が91%) は従来の研究報告と同程度であり、これまでに抽出が困難であった臓器 (例えば、胃、子宮、前立腺) でも提案法では抽出可能であることを確認した。筆者らが知る限り、体幹部CT画像から一括処理で19種類の臓器を同時に抽出できる手法の報告は、本研究[1]が最初である。本手法による自動抽出の計算速度は約0.2秒/断面であり、FCNの学習には約2日間を要した。これは、これまでの臓器抽出システムに比べてはるかに高速であり、処理手順の設計における労力も大きく軽減されたといえる[3]。

## 4. まとめ

本稿では、CT画像からの解剖学的構造 (複数の臓器領域) の自動抽出において、DLのアプローチに基づくFCNを利用した手法について解説した。240例のCT画像を用いた評価結果から、DLを用いる方法は、CT画像からの解剖学的構造の自動抽出問題を効率的に解決できることを示した。

今後は、FCN構造の最適化による抽出精度の向上などの検討[4]を行う予定である。

## 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: 26108005: 「医用画像に基づく計算解剖学の多元化と高度知能化診断・治療への展開」) により行われました。

## 参考文献

- [1] Zhou X, Ito T, Takayama R, et al.: First trial and evaluation of anatomical structure segmentations in 3D CT images based only on deep learning, Brief Article,




Fig.2 本手法による臓器の抽出例。左：手動抽出の結果、右：自動抽出の結果

Medical Image and Information Sciences, 33(3), 69-74, 2016.

- [2] Long J, Shelhamer E, and Darrell T : Fully convolutional networks for semantic segmentation, Proc. CVPR, 3431-3440, 2015.
- [3] Zhou X, Ito T, Takayama R, et al. : Three-dimensional CT image segmentation by combining 2D fully convolutional network with 3D majority voting, Proc. of Workshop on the 2nd Deep Learning in Medical Image Analysis (DLMIA) in MICCAI 2016, LNCS 10008, 111-120, 2016.
- [4] Zhou X, Takayama R, Wang S, et al. : Automated

segmentation of 3D anatomical structures on CT images by using a deep convolutional network based on end-to-end learning approach, Proc. SPIE Medical Imaging 2017, in press, 2017.

#### 転載情報

以下の論文の p.72 の図 3 を利用

X.Zhou, T.Ito, R.Takayama, et al. : First trial and evaluation of anatomical structure segmentations in 3D CT images based only on deep learning, Brief Article, Medical Image and Information Sciences, 33(3), 69-74, 2016.